



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

CLASIFICADOR AUTOMÁTICO DE MODULACIONES APLICADO A SISTEMAS DE GUERRA ELECTRÓNICA.

Autor: Jaime Reglero García

Director: Carlos García de la Cueva

Codirector: Javier Matanza Domingo

Madrid

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
Clasificador automático de modulaciones aplicado a sistemas de guerra electrónica
en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el
curso académico 2021/22 es de mi autoría, original e inédito y
no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido
tomada de otros documentos está debidamente referenciada.



Fdo.: Jaime Reglero García

Fecha: 05/07/2022

Autorizada la entrega del proyecto

DIRECTORES DEL PROYECTO



Fdo.: Carlos García de la Cueva

Fecha: 05/07/2022



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO

CLASIFICADOR AUTOMÁTICO DE MODULACIONES APLICADO A SISTEMAS DE GUERRA ELECTRÓNICA.

Autor: Jaime Reglero García

Director: Carlos García de la Cueva

Codirector: Javier Matanza Domingo

Madrid

Agradecimientos

Me gustaría mostrar mi agradecimiento a los directores de este proyecto por su ayuda y disponibilidad en la realización del trabajo.

CLASIFICADOR DE MODULACIONES APLICADO A SISTEMAS DE GUERRA ELECTRÓNICA

Autor: Reglero García, Jaime.

Director: García de la Cueva, Carlos

Matanza Domingo, Javier

Entidad Colaboradora: ICAI

RESUMEN DEL PROYECTO

En este proyecto se ha desarrollado un clasificador automático de modulaciones basado en una red neuronal artificial (ANN). A partir de un conjunto fijo de muestras de señal, el algoritmo propuesto identifica la forma de onda más probable dentro de un subconjunto de modulaciones predefinido (AM, FM, FSK, PSK, QAM y OFDM).

Los clasificadores de modulaciones son un sistema tecnológico de interés en un amplio número de aplicaciones, tanto militares como civiles, desde la interceptación e inhibición de las comunicaciones en entornos hostiles hasta sistemas de radio cognitiva capaces de conmutar de modulación sin necesidad de un canal de retorno. Típicamente, se basan en la extracción de características de la señal capturada (desviación de amplitud, desviación de frecuencia, ancho de banda, ...), y a partir de estas se identifica la modulación empleando arboles de decisión y/o redes neuronales. La particularidad del clasificador que se describe en este documento reside en que trabaja con las muestras en crudo de la señal, sin obtener ningún estadístico intermedio.

El clasificador desarrollado ha sido entrenado con una batería de señales centradas en frecuencia cero, donde se ha supuesto la presencia previa de un demodulador digital que elimine el error residual en la frecuencia de portadora. Además, el número de entradas de la ANN es fijo. Es decir, ante longitudes de señal mayores al número de entradas de la red, se realiza primero una clasificación individual de cada uno de los sub-bloques, y posteriormente una clasificación global basada en la anterior.

El rendimiento del clasificador se ha evaluado a partir de una base de datos propia que contiene un amplio espectro de relaciones señal a ruido (SNR) y diferentes parámetros de las modulaciones anteriormente definidas. Los resultados se muestran a lo largo del documento en formato de matrices de confusión, donde se comprueba que el sistema logra una probabilidad de correcta clasificación superior al 90% para $SNR \geq 5$ dB.

Palabras clave: Clasificación automática de modulaciones, comunicaciones, Machine Learning, red neuronal artificial

1. Introducción

Tradicionalmente, la clasificación de modulaciones era un proceso realizado manualmente por ingenieros de procesamiento de señales. Sin embargo, lograr niveles de precisión satisfactorios implicaba un gran coste tanto matemático como temporal. Por ello, el interés en la clasificación automática de modulaciones creció considerablemente, representando una alternativa eficiente y de mayor versatilidad.

Este proyecto tiene como objetivo desarrollar un sistema completo de clasificación de modulaciones, para lo cual se creará, en primer lugar, una batería de señales con diferentes modulaciones, para después desarrollar y entrenar una red neuronal artificial. Por tanto, el objetivo final es obtener un sistema capaz de clasificar señales según su modulación, independientemente de los parámetros de dicha modulación.

2. Definición del proyecto

Este proyecto aborda el desarrollo de un sistema clasificador automático de modulaciones empleando técnicas de Machine Learning computacionalmente eficientes, y que no requieran de un gran conocimiento previo. Por ello, se empleará una red neuronal artificial (ANN) que se entrenará con una batería de señales sin ruido previamente generada. Dicha batería de entrenamiento estará formada por señales moduladas en AM, FM, PSK, FSK, QAM y OFDM, con diferentes parámetros para cada modulación. Además, se evaluará el rendimiento del sistema en condiciones no ideales, ya sea con diferentes valores de ruido, o con diferentes longitudes de señal.

3. Descripción del modelo/sistema/herramienta

El trabajo realizado consta de una serie de etapas. En primer lugar, se parte de una señal modulada en una de las modulaciones que se pretenden clasificar. Tras obtener una señal modulada, se introducirá la señal en el sistema, mostrado a continuación:

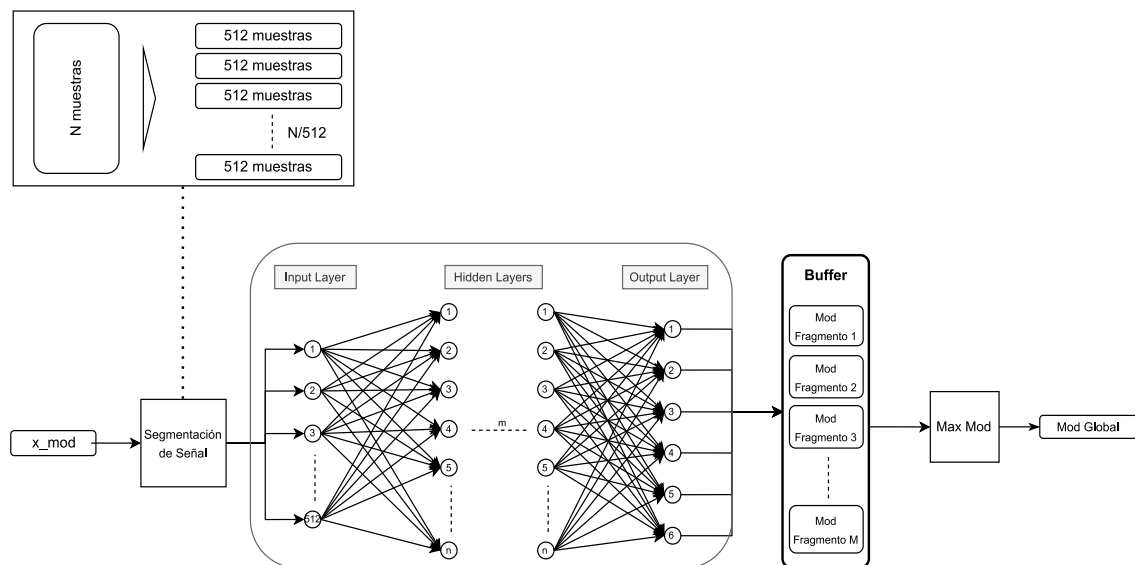


Ilustración 1 - Diagrama de Bloques del Sistema

Una vez se obtiene una señal modulada de longitud N muestras, se descompondrá en bloques de señal de 512 muestras. Posteriormente, cada fragmento de señal será clasificado por la red que previamente hemos entrenado, y la clasificación de cada fragmento será trasladada a un buffer. Finalmente, una vez todos los fragmentos se hayan clasificado se aplicará una regla de máximos para clasificar la señal completa.

4. Resultados

La red neuronal estará formada por una primera capa de 512 neuronas seguida de tres capas de 256 neuronas, una capa de 128 neuronas, una capa de 64 neuronas, una capa de 32 neuronas, y la capa final formada por 6 neuronas. Todas las capas tendrán función de activación Relu menos la última, en la cual se ha optado por la función softmax, al tratarse de un problema de clasificación multiclase.

En primer lugar, se ha entrenado la red con una batería de 115.000 señales sin ruido, logrando una precisión en entrenamiento del 98,63%, y, en mayor grado de detalle, alcanzando una precisión superior al 93% para los 6 tipos de modulaciones estudiadas. Tras constatar el excelente rendimiento de la red neuronal en un ámbito de condiciones ideales se ha comprobado el rendimiento en condiciones más realistas, con diferentes niveles de ruido, y diferentes longitudes de señal, obteniendo los siguientes resultados:

Modulación	SNR (dB)						# Muestras	
	50 dB	40 dB	30 dB	20 dB	10 dB	5 dB	2048	4096
AM	100%	100%	100%	100%	100%	100%	100%	100%
FM	100%	99%	99%	100%	100%	97%	100%	100%
PSK	88%	83%	83%	90%	81%	70%	71%	68%
FSK	100%	100%	100%	100%	100%	97%	66%	67%
QAM	84%	80%	80%	87%	86%	80%	72%	82%
OFDM	100%	100%	100%	100%	100%	99%	78%	87%

Tabla 1 - Resumen Resultados en Condiciones No Ideales

5. Conclusiones

En términos de tolerancia al ruido los resultados alcanzados han sido plenamente satisfactorios, tanto en términos globales, como a nivel de modulación. Es de remarcar la precisión alcanzada para las modulaciones AM, FM, FSK y OFDM, superior al 95% en todos los casos. Igualmente, la introducción de señales con diferentes longitudes ha mostrado resultados satisfactorios, logrando precisiones de clasificación del 81% y 85% para señales de 2048 y 4096 muestras respectivamente. Como se preveía, la precisión es superior para señales con 4096 muestras, ya que los errores de clasificación de fragmento tienen un impacto mucho menor. Tras evaluar el clasificador se puede concluir que existe viabilidad para implantar una red neuronal artificial como sistema clasificador automático de modulaciones, mostrando una gran tolerancia al ruido, y una adaptación a diferentes tamaños de señal aceptable.

6. Referencias

- [1] Azzouz, E., & Nandi, A. K. (2013). Automatic modulation recognition of communication signals
- [2] Zhu, Z., & Nandi, A. K. (2015). Automatic Modulation Classification: Principles, Algorithms and Applications. Wiley

AUTOMATIC MODULATION CLASSIFIER APPLIED TO ELECTRONIC WARFARE SYSTEMS

Author: Reglero García, Jaime.

Supervisor: García de la Cueva, Carlos.

Matanza Domingo, Javier.

Collaborating Entity: ICAI

ABSTRACT

Throughout this project, an automatic modulation classifier based on an artificial neural network (ANN) has been developed. From a fixed set of signal samples, the proposed algorithm identifies the most probable waveform within a predefined subset of modulations (AM, FM, FSK, PSK, QAM, and OFDM).

Modulation classifiers are a technological system of interest in a wide number of applications, both military and civilian, from interception and jamming of communications in hostile environments to cognitive radio systems capable of modulation switching without the need for a return channel. Typically, they are based on the extraction of characteristics of the captured signal (amplitude deviation, frequency deviation, bandwidth, ...), and from these, the modulation is identified using decision trees and/or neural networks. The particularity of the classifier described in this document lies in the fact that it works with the raw samples of the signal, without obtaining any intermediate statistics.

The classifier developed has been trained with a battery of signals centered at zero frequency, where it has been assumed the prior presence of a digital demodulator that eliminates the residual error in the carrier frequency. In addition, the number of inputs to the ANN is fixed. That is, for signal lengths greater than the number of inputs in the network, an individual classification of each of the sub-blocks is performed first, followed by a global classification based on the previous one.

The performance of the classifier has been evaluated based on a proprietary database containing a wide spectrum of signal-to-noise ratios (SNR) and different parameters of the previously defined modulations. The results are shown throughout the document in the form of confusion matrices, where it is shown that the classifier achieves a probability of correct classification of more than 90% for $\text{SNR} \geq 5$ dB.

Keywords: Automatic Modulation Classification, Machine Learning, Communications, Artificial Neural Network

1. Introduction

Traditionally, modulation classification was a manual process performed by signal processing engineers. However, achieving satisfactory levels of accuracy was both mathematically and time-consuming. Therefore, interest in automatic modulation classification grew considerably, representing an efficient and more versatile alternative.

This project aims to develop a complete modulation classification system, for which a battery of signals with different modulations will first be created, and then an artificial neural network will be developed and trained. Therefore, the final objective is to obtain a system capable of classifying signals according to their modulation, independently of the parameters of this modulation.

2. Project Definition

This project deals with the development of an automatic modulation classifier system using computationally efficient Machine Learning techniques that do not require a great deal of prior knowledge. Therefore, an artificial neural network (ANN) will be used, which will be trained with a battery of previously generated noise-free signals. This training battery will consist of AM, FM, PSK, FSK, QAM, and OFDM modulated signals, with different parameters for each modulation. In addition, the performance of the system will be evaluated under non-ideal conditions, either with different noise values or with different signal lengths.

3. Description of the model/system/tool

The work carried out consists of a series of stages. First, a modulated signal in one of the modulations to be classified is used as a starting point. After obtaining a modulated signal, the signal will be introduced into the system, shown below:

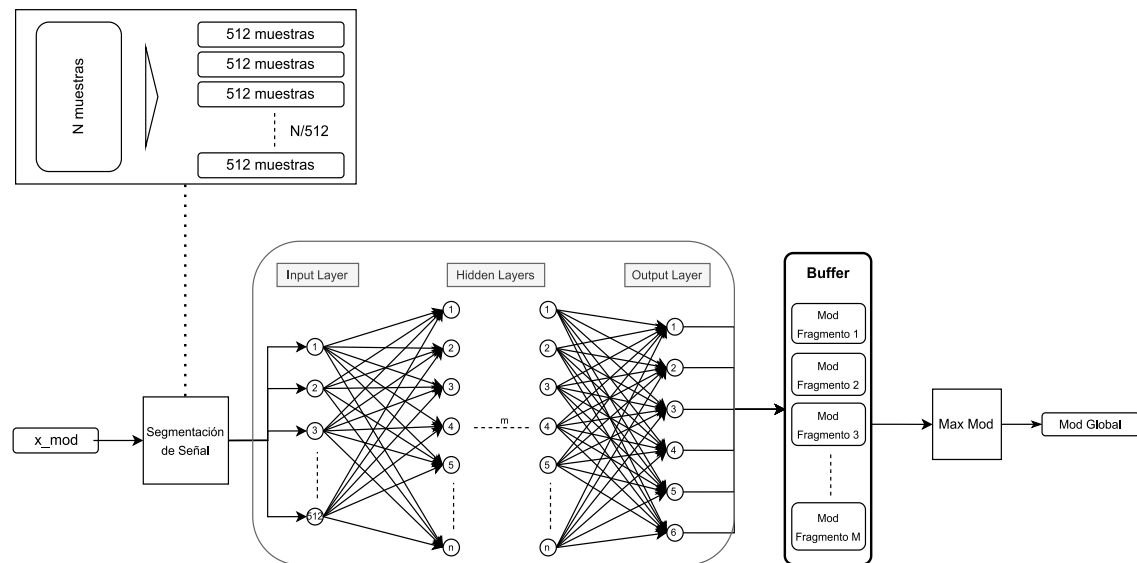


Ilustración 2 - System Block Diagram

Once a modulated signal of length N samples is obtained, it will be decomposed into signal blocks of 512 samples. Subsequently, each signal fragment will be classified by the network that we have previously trained, and the classification of each fragment will be transferred to a buffer. Finally, once all the fragments have been classified, a maximum rule will be applied to classify the complete signal.

4. Results

The neural network will consist of the first layer of 512 neurons followed by three layers of 256 neurons, a layer of 128 neurons, a layer of 64 neurons, a layer of 32 neurons, and the final layer consisting of 6 neurons. All the layers have a Relu activation function except the last one, in which the softmax function has been chosen, as it is a multi-class classification problem.

Firstly, the network was trained with a battery of 115.000 noise-free signals, achieving a training accuracy of 98.63%, and, in greater detail, reaching an accuracy of over 93% for the 6 types of modulations studied. After confirming the excellent performance of the neural network under ideal conditions, the performance of the classifier was tested under more realistic conditions, with different noise levels and different signal lengths, obtaining the following results:

<i>Modulación</i>	<i>SNR (dB)</i>						<i># Muestras</i>	
	50 dB	40 dB	30 dB	20 dB	10 dB	5 dB	2048	4096
AM	100%	100%	100%	100%	100%	100%	100%	100%
FM	100%	99%	99%	100%	100%	97%	100%	100%
PSK	88%	83%	83%	90%	81%	70%	71%	68%
FSK	100%	100%	100%	100%	100%	97%	66%	67%
QAM	84%	80%	80%	87%	86%	80%	72%	82%
OFDM	100%	100%	100%	100%	100%	99%	78%	87%

Tabla 2 - Results Summary under Non-Ideal Conditions

5. Conclusions

In terms of noise tolerance, the results achieved have been fully satisfactory, both in global terms and at the modulation level. It is worth highlighting the accuracy achieved for AM, FM, FSK, and OFDM modulations, above 95% in all cases. Similarly, the introduction of signals of different lengths has shown satisfactory results, achieving classification accuracies of 81% and 85% for signals of 2048 and 4096 samples respectively. As expected, the accuracy is higher for signals with 4096 samples, as fragment classification errors have a much smaller impact. After evaluating the classifier, it can be concluded that it is feasible to implement an artificial neural network as an automatic modulation classifier system, showing a high tolerance to noise, and an acceptable adaptation to different signal sizes.

6. References

- [1] Azzouz, E., & Nandi, A. K. (2013). Automatic modulation recognition of communication signals
- [2] Zhu, Z., & Nandi, A. K. (2015). Automatic Modulation Classification: Principles, Algorithms and Applications. Wiley

Índice de la memoria

Capítulo 1. Introducción.....	21
1.1 Motivación del proyecto	22
Capítulo 2. Estado de la Cuestión.....	24
Capítulo 3. Definición del Trabajo	28
3.1 Justificación	28
3.2 Objetivos.....	29
3.3 Metodología	29
3.4 Planificación y Estimación Económica	31
Capítulo 4. Sistema Desarrollado	32
4.1 Modulaciones	33
4.1.1 Modulación AM.....	34
4.1.2 Modulación FM.....	35
4.1.3 Modulación PSK.....	36
4.1.4 Modulación FSK.....	38
4.1.5 Modulación QAM	39
4.1.6 Modulación OFDM.....	40
4.2 Red Neuronal	42
4.2.1 Aprendizaje.....	43
4.2.2 Funciones de Activación	44
4.2.3 Funciones de Perdida	49
4.2.4 Optimizador.....	49
4.3 Batería de Señales	51
4.4 Entrenamiento de la Red.....	53
Capítulo 5. Evaluación de Resultados	60
5.1 Rendimiento Frente al Ruido	60
5.1.1 SNR = 50 dB.....	60
5.1.2 SNR = 40 dB.....	62

5.1.3 SNR = 30 dB.....	64
5.1.4 SNR = 20 dB.....	66
5.1.5 SNR = 10 dB.....	68
5.1.6 SNR = 5 dB.....	70
5.2 Señales de Mayor Longitud.....	72
5.2.1 Señales de Longitud 2048.....	73
5.2.2 Señales de Longitud 4096.....	75
Capítulo 6. Conclusiones y Trabajos Futuros.....	78
Capítulo 7. Bibliografía.....	83
ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS.....	87

Índice de figuras

Ilustración 1 - Diagrama de Bloques del Sistema	9
Ilustración 2 - System Block Diagram	13
Ilustración 3 - Diagrama de Bloques del Sistema	32
Ilustración 4 - Modulación AM [13]	34
Ilustración 5 - Modulación FM [13].....	36
Ilustración 6 - Modulación BPSK [14].....	37
Ilustración 7 - Modulación FSK [8]	38
Ilustración 8 - Modulación 16-QAM [3]	40
Ilustración 9 - Esquema Modulación OFDM [16]	41
Ilustración 10 - Espectro de Subportadoras OFDM [19].....	42
Ilustración 11 - Representación Multi-Perceptron	45
Ilustración 12 - Función Activación Relu [2]	46
Ilustración 13 - Función Activación Sigmoide [23].....	47
Ilustración 14 - Función Activación Tangente Hiperbólica [4]	48
Ilustración 15 - Diseño Red Neuronal	54
Ilustración 16 - Pérdidas en Entrenamiento y Validación (SNR = ∞)	56
Ilustración 17 - Precisión en Entrenamiento y Validación (SNR = ∞)	56
Ilustración 18 - Matriz de Confusión Absoluta (SNR = ∞).....	57
Ilustración 19 - Matriz de Confusión Porcentual (SNR = ∞)	58
Ilustración 20 - Matriz de Confusión Porcentual (SNR = 50dB).....	61
Ilustración 21 - Matriz de Confusión Porcentual (SNR = 40dB).....	63

Ilustración 22 - Matriz de Confusión Porcentual (SNR = 30dB).....	65
Ilustración 23 - Matriz de Confusión (SNR = 20dB)	67
Ilustración 24 - Matriz de Confusión Porcentual (SNR = 10dB).....	69
Ilustración 25 - Matriz de Confusión Porcentual (SNR = 5dB).....	71
Ilustración 26 - Matriz de Confusión Señal de Longitud 2048 (SNR = 20dB)	74
Ilustración 27 - Matriz de Confusión Señal de Longitud 4096 (SNR = 20dB)	76
Ilustración 28 - Precisión en función de SNR.....	79

Índice de tablas

Tabla 1 - Resumen Resultados en Condiciones No Ideales.....	10
Tabla 2 - Results Summary under Non-Ideal Conditions.....	14
Tabla 3 - Planificación del Proyecto	31
Tabla 4 - Resumen Precisión en función SNR.....	80
Tabla 5 - Resumen Precisión en función de Tamaño	81

Capítulo 1. INTRODUCCIÓN

A lo largo de la historia, numerosos avances tecnológicos y científicos han emanado de investigaciones o estudios de carácter militar, para posteriormente cumplir una utilidad para la sociedad global. Entre dichos avances se encuentra la clasificación automática de modulaciones (AMC), automatic modulation classification. Los clasificadores de modulaciones son de interés en un amplio número de aplicaciones, desde la interceptación e inhibición de las comunicaciones en entornos hostiles hasta sistemas de radio cognitiva capaces de conmutar de modulación si necesidad de un canal de entorno.

Tradicionalmente, la clasificación de modulaciones era un proceso que se realizaba manualmente por ingenieros de procesamiento de señales, que, con la ayuda de instrumentos de medida eran capaces de identificar la modulación en cuestión. Sin embargo, este proceso tenía un gran coste, y requería de una mayor inversión temporal para poder obtener un resultado satisfactorio. Por ello, a lo largo de las décadas de 1980 y 1990, creció considerablemente el interés en la clasificación automática de modulaciones, culminando con la publicación del primer libro relacionado con el problema en cuestión en 1996 por Azzouz y Nandi.

Desde entonces, numerosos avances fueron realizados, y, gracias al incremento de la capacidad computacional en el campo de los microprocesadores, la utilidad y eficiencia de los sistemas de clasificación automática de modulaciones incrementó exponencialmente. Como tal, se comenzó a implantar tanto en escenarios militares, como la interceptación de mensajes enemigos o la introducción de interferencias intencionadas que perturben la comunicación, como civiles, destacando su uso en la adaptación de enlace (LA) cuyo objetivo es optimizar la transmisión adaptando el esquema de modulación de la señal en función de las condiciones del canal.

Este proyecto busca desarrollar un sistema completo de clasificación automática de modulaciones. Para ello, se creará, en primer lugar, una batería de señales con diferentes modulaciones, implementando diferentes variaciones para cada modulación, para, posteriormente, empleando técnicas de Machine Learning basadas en redes neuronales crear un clasificador automático de modulaciones. El objetivo final, por tanto, es obtener un sistema automático capaz de clasificar señales de acorde a su modulación, independientemente de los parámetros de dicha modulación.

1.1 MOTIVACIÓN DEL PROYECTO

Como se ha explicado anteriormente, los sistemas de clasificación automática de modulaciones presentan una gran variedad de utilidades, ya sean aplicaciones de guerra electrónica o aplicaciones al mundo civil. Sin embargo, su desarrollo e investigación es relativamente reciente, por lo que se pretende poder profundizar en dicho ámbito y sus diferentes aplicaciones.

En segundo lugar, como parte de este trabajo no solo se desarrollará el sistema de clasificación de modulaciones, sino que también se deberá generar una batería sintética de señales de diferentes modulaciones, incluyendo diferentes variaciones en los principales parámetros de cada modulación. La motivación principal de este proyecto es generar un clasificador capaz de identificar la modulación de la señal analizada de entre un subconjunto amplio de categorías.

Por otro lado, uno de los componentes claves en el desarrollo del proyecto será el desarrollo del clasificador. Dentro de los diferentes clasificadores principales, en los que se indaga en mayor medida en el estado de la cuestión, existen dos tipos de clasificadores principales: los clasificadores basados en características, y los clasificadores basados en verosimilitud. En este caso, sin embargo, desarrollaremos un clasificador empleado en menor medida, los clasificadores sin preprocesado de señal. Esto en si constituye una de las motivaciones del

proyecto, ya que los clasificadores basados en verosimilitud y características son de mayor popularidad, y, por lo tanto, se pretende indagar acerca de las posibilidades y el rendimiento de los clasificadores sin preprocesado de señal.

Capítulo 2. ESTADO DE LA CUESTIÓN

El desarrollo de sistemas de clasificación automática de modulaciones, como hemos comentado anteriormente, es un problema de relativamente reciente introducción al ámbito investigador, surgiendo a lo largo de las décadas de 1980 y 1990. Por ello, el rendimiento de dichos sistemas clasificadores ha ido mejorando a medida que la investigación en torno a ellos incrementaba, surgiendo mejoras en la precisión de los clasificadores, la consistencia, la eficiencia y la versatilidad.

Antes que nada, cabe destacar los diferentes tipos de clasificadores empleados en la actualidad. Podemos distinguir dos principales tipos de clasificadores, aquellos basados en características y aquellos basados en verosimilitud. Los clasificadores basados en características emplean árboles de decisión para, de acuerdo con unas características previamente definidas, diferenciar los diferentes tipos de modulaciones. En cambio, los clasificadores basados en verosimilitud tratan de buscar la clase, en este caso el tipo de modulación, que maximice la función de verosimilitud de la muestra observada. Además de los dos tipos de clasificadores mencionados, existe un tipo de clasificador menos común, aquellos que no realizan ningún tipo de preprocesado de señal, que será el empleado para el desarrollo del trabajo.

En primer lugar, comenzaremos indagando en los clasificadores basados en características. Como hemos comentado anteriormente, el proceso de clasificación requiere del desarrollo de un árbol de decisión, que dependerá de las características empleadas para el desarrollo del clasificador. Por ello, existen multitud de clasificadores con diferentes características. Uno de los principales tipos de características empleadas para desarrollar clasificadores son las relacionadas con el espectro de la señal, principalmente en los ámbitos de amplitud, fase o frecuencia. En [1] se enumeraron una serie de características relacionadas con el espectro de la señal para el desarrollo de clasificadores óptimos. Entre ellas, encontramos

el valor máximo de la densidad espectral de potencia, dada una señal normalizada y centrada. Otra característica propuesta es la desviación típica del valor absoluto de la componente no-lineal de la fase instantánea de la señal recibida. Asimismo, se propone emplear como característica la desviación típica del valor absoluto de la amplitud, dada la amplitud como una señal centrada y normalizada. Finalmente, se propone la utilización de la desviación típica del valor absoluto de la frecuencia instantánea, dada la frecuencia instantánea como una señal centrada y normalizada. Para concluir, teniendo en cuenta las características decididas para el desarrollo del clasificador, se procederá a construir un árbol de decisión que, para cada característica tendrá un umbral y concluirá asignando un tipo de modulación.

Como se ha comentado, existen multitud de clases de características. Otro tipo de características empleadas habitualmente son las basadas en la transformada Wavelet. Este tipo de clasificación es desarrollado en [11], y permite distinguir claramente modulaciones PSK y FSK, a través del análisis de la expresión de sus respectivas transformadas Wavelets continuas (CWT). Realmente, la única debilidad de este tipo de clasificación viene a la hora de distinguir modulaciones ASK y QAM, para lo cual, como citado en [9], se propone emplear el concepto del momento matemático para describir las diferencias entre dichas modulaciones, técnica ya empleada anteriormente por [21] para la clasificación de modulaciones M-PSK.

Habiendo comentado brevemente los diferentes tipos de clasificadores basados en características, procederemos a comentar la clasificación basada en verosimilitud. En primer lugar, comentaremos los clasificadores de máxima verosimilitud, aquellos en los que se conocen todos los parámetros del canal. Estos clasificadores buscan maximizar la probabilidad de que la muestra observada pertenezca a un tipo de modulación, siendo la principal tarea la derivación de la función de verosimilitud. Una vez se tiene la función de verosimilitud, se evalúa cada tipo de modulación, y se toma la decisión escogiendo el máximo valor de dicha función. Este tipo de método de clasificación es el empleado por [22], que aplica el método de máxima verosimilitud a la clasificación de modulaciones de

amplitud en cuadratura.

Anteriormente, se ha mencionado que los clasificadores de máxima verosimilitud se emplean en casos en los que se conocen todos los parámetros del canal, lo cual no siempre ocurre. En dichos casos, se emplea el test del ratio de verosimilitud medio, que reemplaza aquellos parámetros no conocidos por la integral de los posibles valores y sus probabilidades correspondientes. De esta manera, al igual que con el método de máxima verosimilitud, la decisión de clasificación se tomará escogiendo el máximo valor del ratio de verosimilitud medio. Este tipo de clasificador es el empleado por [12] en la clasificación de modulaciones M-PSK. Sin embargo, el empleo del ratio de verosimilitud medio es de una gran complejidad, por lo que surgieron otras alternativas, como el ratio de verosimilitud generalizado, desarrollado en [17] que reemplaza parámetros desconocidos por el valor de máxima verosimilitud dentro del rango de dicho parámetros, de manera que la complejidad del modelo es reducida inmensamente.

Como se ha comentado anteriormente, existe otra rama diferente a los clasificadores automáticos de modulaciones tradicionales, aquellos que no realizan ningún tipo de preprocesado de señal. Dichos tipos de clasificadores surgen para ofrecer una alternativa de menor complejidad y que conlleven un menor coste computacional que los clasificadores basados en características o en verosimilitud. Típicamente, los clasificadores sin preprocesado de señal se basan en técnicas de Deep Learning, comúnmente redes neuronales convolucionales. Este es el enfoque empleado por [15], que emplean una red neuronal convolucional (CNN) como base del sistema clasificador. En dicho artículo concluyen que el clasificador muestra un rendimiento superior a aquellos clasificadores basados en características, y supone una aproximación a los clasificadores basados en verosimilitud en un tiempo de computación exponencialmente menor, de 40 a 1700 veces.

Asimismo, en [18] se estudia el rendimiento de diferentes tipos de redes neuronales, para clasificar una batería de señales de 10 modulaciones diferentes. En dicho artículo, se estudian tres tipos de redes neuronales diferentes: una red neuronal profunda convolucional

(CLDNN), una red neuronal de memoria de largo y corto plazo (LSTM) y una red residual profunda (ResNet). Dichas redes neuronales son de una alta complejidad, y demuestran una gran robustez para diferentes niveles de nivel señal a ruido (SNR), así como altos niveles de precisión tanto en la fase de entrenamiento como de clasificación, en torno al

De la misma manera, en [7] se expone el rendimiento de una red neuronal profunda. Para el desarrollo de dicha red, parten de una red neuronal convolucional tradicional, y buscan optimizar sus hiperparámetros para cada valor diferente SNR. De esta manera consiguen alcanzar un gran rendimiento, obteniendo una precisión superior al 80% en señales con relaciones señal a ruido (SNR) cercanas a 0 dB, y alrededor de un 90% para señales con SNR superior a 10 dB.

Capítulo 3. DEFINICIÓN DEL TRABAJO

3.1 JUSTIFICACIÓN

Actualmente, como hemos detallado a lo largo del estado de la cuestión, la mayoría de los desarrollos de sistemas clasificadores automáticos de modulaciones consisten en clasificadores basados en verosimilitud, con un alto coste computacional, o clasificadores basados en características, que requieren una gran cantidad de conocimientos previos para la extracción de características.

En los últimos años, como alternativa a los clasificadores mencionados, han comenzado a surgir numerosas propuestas de sistemas clasificadores automáticos de modulaciones basados en técnicas de Machine Learning. Estos clasificadores aportan una mayor versatilidad y robustez frente a diferentes tipos de modulaciones, a la vez que ofrecen una alternativa de menor coste computacional y complejidad. Sin embargo, como hemos detallado, la gran mayoría de desarrollos se centran en redes neuronales profundas, como pueden ser las redes neuronales convolucionales (CNN) o las redes neuronales residuales (ResNet), redes neuronales de un alto grado de complejidad, y que requieren un gran entendimiento previo de las redes neuronales. Como es de esperar, además, el alto grado de complejidad de dichas redes, supone también un mayor coste computacional, que no está al alcance de todos.

Como tal, pues, este proyecto pretende abordar la cuestión del desarrollo de un sistema clasificador automático de modulaciones empleando técnicas elementales de Machine Learning, que no requieran de un extenso conocimiento previo. Es por ello, por lo que se empleará una red neuronal artificial (ANN), el tipo de red neuronal más simple, y con una menor curva de aprendizaje. Por tanto, se pretende desarrollar un sistema clasificador automático de modulaciones que no requiera un alto nivel de conocimiento previo, no

conlleve un alto coste computacional, y, que, a la vez, alcance unos niveles de rendimiento adecuados y satisfactorios.

3.2 OBJETIVOS

El objetivo principal de este proyecto, como se ha ido comentando, es el desarrollo de un sistema de clasificación automática de modulaciones preciso, capaz de adaptarse a una batería de modulaciones diferentes. Más aún, para el desarrollo de dicho clasificador, emplearemos técnicas de Machine Learning, concretamente desarrollaremos una red neuronal artificial (ANN). Para ello, por tanto, se deberán cumplir una serie de objetivos intermedios que detallaremos a continuación de acuerdo con su naturaleza:

1. Didácticos
 - Profundizar en conocimientos de Machine Learning, particularmente en el desarrollo de redes neuronales y su correspondiente algoritmo de entrenamiento basado en la técnica de propagación hacia atrás
2. Técnicos
 - Generación de una batería completa de señales con amplia variedad de modulaciones
 - Diseñar el sistema de clasificación creando una red neuronal y posteriormente entrenar dicha red neuronal por medio de la técnica de propagación hacia atrás
 - Comprobar el correcto funcionamiento y la precisión del sistema de clasificación desarrollado frente a otros clasificadores

3.3 METODOLOGÍA

En primer lugar, debemos destacar que el desarrollo técnico del trabajo, es decir la generación de la batería de señales y el diseño y entrenamiento de la red neuronal, se

realizará en el lenguaje de programación Matlab. Se ha escogido Matlab porque se considera que es un lenguaje de gran versatilidad, ampliamente usado en el ámbito de las telecomunicaciones y, por tanto, óptimo para generar la batería de señales.

En cuanto a la red neuronal se refiere, en un primer momento se optó por el lenguaje Matlab, particularmente usando el toolbox de Machine Learning, para mantener la homogeneidad de lenguajes. Sin embargo, se ha optado por desarrollarla en Python, empleando la librería Keras, ya que nos aporta una manera de desarrollar y entrenar redes neuronales con gran capacidad de clasificación de manera simple. De la misma manera, Matlab ofrece la opción de desarrollar redes neuronales de manera simple, pero la potencia computacional, y, particularmente, la velocidad y eficiencia es inferior a la ofrecida por Keras y Python.

Teniendo eso en cuenta, se el proyecto comenzó con un periodo de familiarización y aprendizaje de los conceptos básicos alrededor de las redes neuronales y su diseño y aplicación. Posteriormente, se desarrolló una red neuronal básica empleando un dataset de carácter académico (MNIST), para obtener una visión de su aplicación, y, de forma didáctica aprender a desarrollar, entrenar y evaluar una red neuronal.

Teniendo una base sólida de conocimientos de Machine Learning, y, particularmente, de la base conceptual de las redes neuronales, se pasó a una fase que consistió en el estudio de diferentes modulaciones, y una posterior selección de las modulaciones que se pretenden clasificar: AM, FM, PSK, FSK, QAM y OFDM.

Una vez se escogieron las diferentes modulaciones, se desarrollaron sus respectivas funciones en Matlab, para poder generar una amplia batería de señales. Con las funciones de cada modulación desarrolladas, se generó una batería de señales de entrenamiento y otra de testing, variando una serie de parámetros que se comentarán en capítulos posteriores. Con dicha batería de señales de entrenamiento se procedió a comenzar la fase de entrenamiento de la red neuronal.

Finalmente, se evaluó el rendimiento de la red para diferentes niveles de relación señal a ruido, en dB, y para diferentes longitudes de señal, pudiendo así obtener una visión completa del rendimiento de la red.

3.4 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA

La planificación del proyecto llevada a cabo ha sido la siguiente:

Tareas	OCTUBRE				NOVIEMBRE				DICIEMBRE				ENERO				FEBRERO				MARZO				ABRIL				MAYO				JUNIO			
	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4
PROFUNDIZACIÓN CONOCIMIENTOS DE MACHINE LEARNING Y REDES NEURONALES																																				
DESARROLLO RED NEURONAL GENÉRICA CON FINES DIDÁCTICOS																																				
ESTUDIO DIFERENTES MODULACIONES																																				
GENERACIÓN BATERÍA DE SEÑALES																																				
ENTRENAMIENTO DE LA RED CON SEÑALES GENERADAS																																				
COMPARACIONES Y PRUEBAS DE RENDIMIENTO																																				
ELABORACIÓN DE LA MEMORIA																																				

Tabla 3 - Planificación del Proyecto

En cuanto a la estimación económica, los recursos empleados para el proyecto son todos de acceso libre, por lo que se podría considerar cercana a 0€.

Capítulo 4. SISTEMA DESARROLLADO

El trabajo realizado consta de una serie de fases o etapas, que culminan en los resultados que posteriormente se evaluarán.

En primer lugar, se partirá de una señal generada, que, de forma aleatoria escogerá uno de los tipos de modulación. Asimismo, para cada modulación se escogerá, de nuevo, de forma aleatoria un posible valor para los parámetros que conforman dicha modulación, siguiendo en ambos casos una distribución uniforme.

Tras obtener una señal modulada, se introducirá la señal en el sistema, el cual se muestra a continuación:

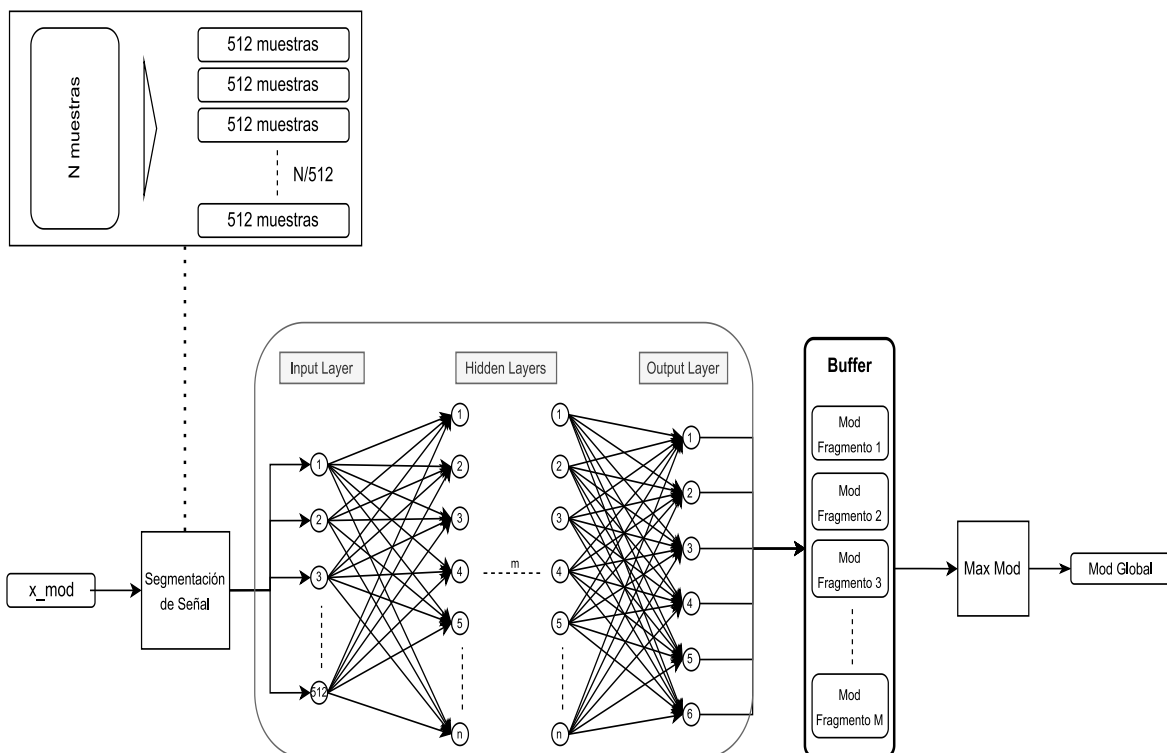


Ilustración 3 - Diagrama de Bloques del Sistema

Como se puede comprobar en el diagrama de bloques, mostrado en la Ilustración 3, una vez se obtiene una señal modulada, de longitud N muestras, el primer paso será descomponer la señal en bloques de señal de 512 muestras, en caso de que la longitud sea mayor a 512 muestras. A partir de aquí, cada bloque de señal será clasificado por la red que previamente hemos entrenado, y la clasificación en cuestión será trasladada a un buffer. Finalmente, una vez todos los bloques se hayan clasificados, las diferentes clasificaciones se extraerán del buffer, y se aplicará una regla de máximos para escoger la modulación de la señal completa.

Teniendo en cuenta las diferentes fases que acabamos de comentar, en los siguientes apartados del presente capítulo detallaremos más a fondo el contenido de cada fase y las diferentes consideraciones a tener en cuenta.

4.1 MODULACIONES

Anteriormente se ha comentado que una de las primeras fases consistió en un estudio de las principales modulaciones empleadas en la transmisión de señales, y en el ámbito de las comunicaciones en general. Tras ese estudio, se alcanzó una lista de modulaciones que se estudiarán y las cuales pretendemos clasificar satisfactoriamente: AM, FM, PSK, FSK, QAM y OFDM. En los subapartados mostrados a continuación, explicaremos brevemente el concepto detrás de cada modulación.

Para el diseño de dichas funciones, en el caso de las modulaciones AM y FM se ha tratado de partir de una señal de voz, modelada con una señal de ruido blanco y un filtro gaussiano. Por otro lado, en los casos de PSK, FSK, QAM y OFDM se han generado vectores de símbolos aleatorios con distribución uniforme, a partir de los cuales se genera la señal modulada. Esta aleatoriedad permitirá que el clasificador se comporte mejor y tenga una mayor capacidad de abstracción frente a señales diferentes. Además, para el caso de PSK y QAM, se han introducido alteraciones de fase aleatorias, que permitan así obtener un mayor grado de abstracción y robustez del clasificador.

4.1.1 MODULACIÓN AM

La modulación AM, amplitude modulation, es un tipo de modulación en el que la amplitud de la señal portadora varía en proporción con los cambios en la amplitud instantánea de la señal moduladora. Es decir, se emplea una señal portadora que no contiene información, y la amplitud de dicha señal portadora se varía en función de la amplitud de la señal moduladora, la cual contiene la información que queremos transmitir.

En la Ilustración 4, mostrada a continuación, se muestra una representación gráfica de lo anteriormente comentado:




Ilustración 4 - Modulación AM [13]

En este caso, la figura muestra una señal modulada en AM con índice de modulación $a = 1/2$. El índice de modulación es el otro aspecto clave de la modulación AM, y actúa como un factor de escala, que nos permite establecer un rango de amplitudes.

Finalmente, cabe mencionar la expresión general de una señal modulada en amplitud, mostrada a continuación, siendo $m(t)$ la señal moduladora, y $c(t)$ la señal portadora:

$$s(t) = A_c * [1 + m(t)] * \cos (w_c t + \theta)$$

4.1.2 MODULACIÓN FM

Al igual que la modulación en amplitud, AM, la modulación en frecuencia, FM, es empleada en numerosas situaciones en el ámbito de las comunicaciones. En el caso de la modulación FM, sin embargo, es la frecuencia de la señal portadora la componente que varía en función de la amplitud de la señal moduladora. Por lo tanto, mientras que en la modulación AM se varía la amplitud de la portadora, en el caso de la modulación FM se varía la frecuencia de la señal portadora.

La figura mostrada a continuación, Ilustración 5, ilustra un ejemplo de una señal modulada en FM:




Ilustración 5 - Modulación FM [13]

La figura mostrada ilustra una señal modulada en FM con constante de desviación de frecuencia $k_f = 2\pi/4$. Este parámetro, de forma similar al índice de modulación AM, pondera el grado de desviación de frecuencia de la señal modulada respecto a la señal portadora. Por otro último, podemos expresar una señal modulada en frecuencia, FM, de acuerdo a la siguiente ecuación:

$$s(t) = A_c * \cos \left(\omega_c t + \left(2\pi * k_f * \int_{-\infty}^t m(\tau) d\tau \right) \right)$$

4.1.3 MODULACIÓN PSK

La modulación PSK (phase shift keying), o modulación por desplazamiento de fase, es un tipo de modulación angular en el que se varía la fase de una señal portadora acorde a una serie de valores discretos, que vienen condicionados por una señal digital de entrada. A

diferencia de la modulación PM, en el caso de las modulaciones PSK la señal de entrada es digital, por lo que la variación de fase no es continua, sino que está limitada a un número de valores discretos, que pueden ser considerados como estados diferentes.

La fase, por tanto, vendrá determinada por una señal digital de entrada. Esto significa, que, en función del número de bits de entrada de la señal digital, existen diferentes ordenes de modulación PSK, siendo las más comunes BPSK (señal digital de entrada binaria) y QPSK (señal digital de entrada de 2 bits). Por tanto, para cada valor de la entrada existirá un valor de fase diferente, en el caso de BPSK son 2 y en el caso de QPSK existen 4 valores de fase.

A continuación, mostramos una ilustración de una señal modulada en BPSK de acuerdo a una señal de entrada binaria:




Ilustración 6 - Modulación BPSK [14]

4.1.4 MODULACIÓN FSK

La modulación FSK (frequency shift keying), o modulación por desplazamiento en frecuencia, es una técnica de modulación angular en la que se varía la frecuencia de una señal portadora en función de una señal digital de entrada.

La modulación FSK es una modulación análoga a PSK, pero en vez de ocurrir una variación en fase ocurre en frecuencia. Por tanto, de acuerdo con el número de bits de la señal digital de entrada existirán un número determinado de valores de frecuencia, concretamente 2^n valores diferentes, siendo n el número de bits de la señal de entrada.

A continuación, mostramos una ilustración de una señal modulada en FSK para una señal de entrada binaria:




Ilustración 7 - Modulación FSK [8]

4.1.5 MODULACIÓN QAM

La modulación QAM (quadrature amplitude modulation), es una técnica de modulación que transporta dos señales independientes, moduladas tanto en amplitud como en fase.

En este caso, se recibe una señal de entrada digital de la cual se generan 2^n estados diferentes, siendo n el número de bits de la señal de entrada, de manera que cada estado diferente tiene una alteración en fase y otra en amplitud. Dichos estados de modulación se representan habitualmente en constelaciones QAM, diagramas mediante los cuales se representan los diferentes estados en dos ejes: I (en fase) y Q (en cuadratura). Finalmente, el módulo viene dado por la distancia entre el origen y el punto de la constelación, y la fase viene dada por el ángulo entre el eje horizontal (eje I) con el punto de la constelación.

A continuación, mostramos un ejemplo de un diagrama de constelación para la modulación 16-QAM:




Ilustración 8 - Modulación 16-QAM [3]

4.1.6 MODULACIÓN OFDM

La última modulación que se estudiará, y, por tanto, se tratará de clasificar es la modulación OFDM (orthogonal frequency division multiplexing), o modulación por división de frecuencias ortogonales.

En la modulación OFDM se divide el espectro disponible en una serie de subcanales en los que la información se modula en múltiples portadoras, cada una a distinta frecuencia. De esta manera, se siguen principios muy similares a los establecidos en FDM (frequency division multiplexing) con la particularidad de que en OFDM las frecuencias son ortogonales entre sí.

Habitualmente, la forma de modular una señal en OFDM se realiza a través de la transformada inversa discreta de Fourier, IDFT. A continuación, mostramos un esquema de modulación de una señal en OFDM:

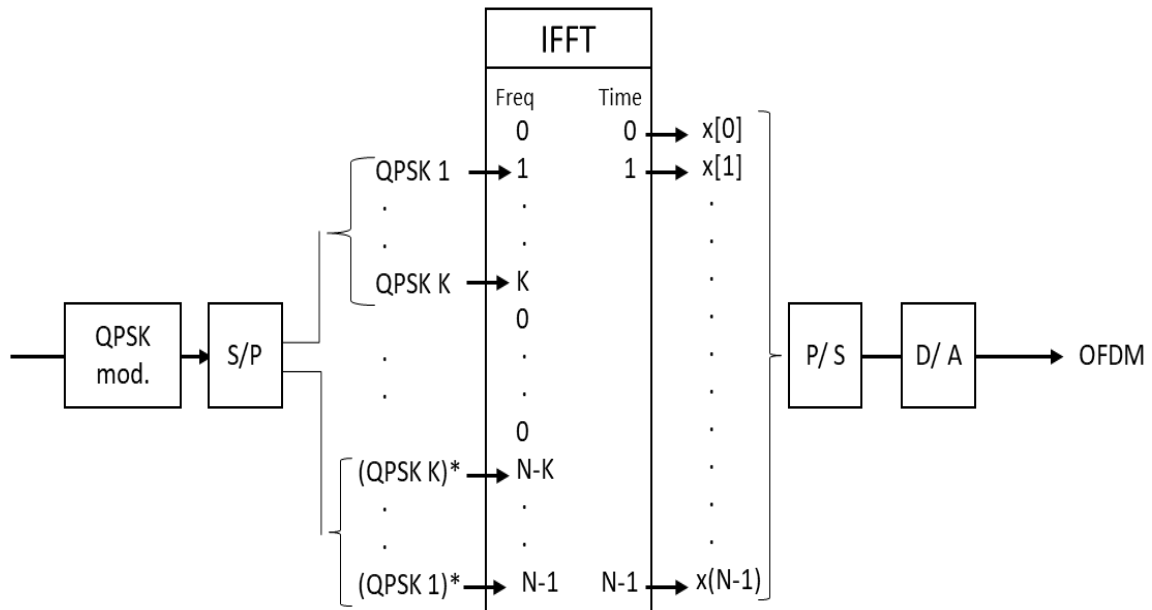


Ilustración 9 - Esquema Modulación OFDM [16]

Finalmente, de modo ilustrativo, en la siguiente ilustración mostramos un ejemplo del espectro de 4 subportadoras de una señal OFDM:




Ilustración 10 - Espectro de Subportadoras OFDM [19]

4.2 RED NEURONAL

Las redes neuronales son una de las técnicas de Inteligencia Artificial de mayor popularidad y con mayor grado de uso en los últimos años. Su origen se remonta al desarrollo del perceptrón, pero el uso de las redes neuronales ha aumentado exponencialmente con el aumento de capacidad de procesamiento de las GPUs, que, en los últimos años, han permitido que el entrenamiento de una red neuronal sea una tarea factible y eficiente, e incluso logre superar el rendimiento de otros algoritmos usados habitualmente.

Al igual que el aumento de la capacidad de procesamiento ha actuado como un catalizador para que el uso de las redes neuronales se haya extendido con tanta velocidad, las ventajas y prestaciones que presentan han permitido que las redes neuronales se mantengan como una de las primordiales técnicas de aprendizaje.

Entre dichas ventajas podemos destacar su capacidad para lidiar con problemas de altas dimensiones, su versatilidad en el tratamiento de diferentes tipos de variables, su capacidad

de paralelización, gracias al uso de las GPUs, y la posibilidad de utilizar un modelo ya entrenado en otros problemas similares.

Estas ventajas han sido las que nos han llevado a optar por el uso de redes neuronales en el desarrollo de este proyecto, considerando que son el tipo de algoritmo o modelo de aprendizaje idóneo para el problema en cuestión. Teniendo esto en cuenta, vamos a indagar brevemente en los principales componentes de las redes neuronales.

4.2.1 APRENDIZAJE

Las redes neuronales basan su aprendizaje en el algoritmo de backpropagation, o propagación hacia atrás. Como se indica en [6], el algoritmo de propagación hacia atrás trata de minimizar una función, la función de pérdidas, ajustando iteración a iteración los valores de los pesos.

Para ello, el algoritmo consta de una serie de pasos:

1. Se introduce un lote de entrada proveniente del dataset de entrenamiento
2. Se propagan las entradas y se obtiene un valor de salida
3. Se utiliza la salida obtenida para evaluar la función de pérdidas
4. Se calcula el gradiente de la función de pérdidas, obteniendo la derivada de la función
5. Se actualizan los pesos de la red restando a su valor actual el valor del gradiente correspondiente, multiplicado por una tasa de aprendizaje

Por tanto, la base del algoritmo reside en obtener el gradiente de la función de pérdidas con respecto a los pesos de la red. Intuitivamente, el gradiente nos indicará en qué sentido aumenta en mayor medida la función de pérdidas, por lo que, dado que el objetivo es minimizarla, se deberán ajustar los pesos en el sentido contrario.

Por otro lado, la tasa de aprendizaje determinará la magnitud de las variaciones que se aplican a los pesos de la red, y, por tanto, alcanzar un valor óptimo será de vital importancia, ya que un valor excesivamente bajo puede llevar a un aprendizaje muy lento, y un valor muy alto puede llevar a oscilaciones.

4.2.2 FUNCIONES DE ACTIVACIÓN

La función de activación de un nodo de una red neuronal, tal y como se explica en [20], es la función que se aplica a una entrada o un conjunto de entradas para definir la salida de dicho nodo. De esta manera, una función de activación permite que la red neuronal modele comportamientos de diferentes indoles, sin ceñirse únicamente a comportamientos lineales.

En la siguiente ilustración, podemos ver representado gráficamente el papel de las funciones de activación:




Ilustración 11 - Representación Multi-Perceptron

Como podemos ver, después de aplicar los pesos a cada entrada de la red, se aplica la función de activación en cuestión, por lo que serán una componente de gran importancia. A continuación, desglosaremos las principales funciones de activación disponibles.

4.2.2.1 Relu

La función de activación relu, rectified linear unit, es una de las funciones de activación más empleadas en la actualidad.

Su popularidad se debe a su labor en combatir el problema de desvanecimiento de gradientes, el cual ocurre debido a la naturaleza del algoritmo de propagación hacia atrás. Dado que el gradiente de una neurona vendrá dado por la regla de la cadena, este vendrá determinado por los gradientes de las capas anteriores. Esto, sumado al hecho de que muchas funciones de activación, como la sigmoide, tienen valores cercanos a 0, hará que, al aumentar el número

de capas, el gradiente se vaya acercando a 0, ya que estaremos multiplicando muchos números menores que 1. La función relu, en cambio, tiene como derivada 1, por lo que el problema del desvanecimiento de gradientes se aplaca.

A continuación, mostramos una imagen de la función de activación relu:




Ilustración 12 - Función Activación Relu [2]

4.2.2.2 Función Sigmoide

La función sigmoide es otra de las funciones usadas más ampliamente, dado que está acotada entre 0 y 1. Esta cualidad la hace particularmente adecuada para aquellos casos en los que se pretende obtener una probabilidad, razón por la cual es la función utilizada de forma estándar para problemas de clasificación binaria.

En cuanto a la formulación matemática, la función sigmoide viene dada por la siguiente expresión:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

Finalmente, en la ilustración a continuación se muestra la representación gráfica de la función sigmoide:




Ilustración 13 - Función Activación Sigmoide [23]

4.2.2.3 Función Softmax

La tercera función de activación que se comentará es la función softmax, una generalización de la función sigmoide para problemas de clasificación multiclase. En este caso, la función softmax establece todos los inputs entre 0 y 1, actuando por tanto como si de una probabilidad se tratara.

La formulación matemática que define la función softmax viene definida por la siguiente expresión:

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_j x_j}$$

Como se ha comentado anteriormente, es una función muy similar a la función sigmoide, pero diseñada para problemas de clasificación multiclase, en lugar de problemas de clasificación binaria.

4.2.2.4 Función Tangente Hiperbólica

La cuarta función de activación de interés es la función tangente hiperbólica. Esta función es similar a la función sigmoide, pero con la particularidad de que el rango de la función está entre -1 y 1, en vez de entre 0 y 1 como es el caso de la función sigmoide. Esto permite que en los casos en los que haya entradas negativas se distingan en mayor medida a aquellas entradas positivas o cercanas a 0.

A continuación, mostramos una representación gráfica de la función.




Ilustración 14 - Función Activación Tangente Hiperbólica [4]

4.2.3 FUNCIONES DE PERDIDA

Uno de los componentes esenciales para el desarrollo de una red neuronal es la función de pérdida, siendo la componente que se busca minimizar durante el entrenamiento. Existen numerosas funciones de pérdida, que se pueden clasificar en función de la naturaleza del problema de la siguiente manera:

- Regresión
 - Mean Squared Error (MSE): computa la media de los cuadrados de los errores entre las etiquetas y las predicciones.
 - Mean Absolute Error (MAE): computa la media del valor absoluto de la diferencia entre los valores reales y las predicciones.
 - Mean Absolute Percentage Error (MAPE): calcula el valor absoluto del error medio porcentual entre las predicciones y los valores reales.
- Clasificación
 - Binary Crossentropy: calcula la pérdida de entropía entre las etiquetas verdaderas y las predichas en un problema de clasificación binaria.
 - Categorical Crossentropy: calcula la pérdida de entropía entre las etiquetas verdaderas y las predichas en un problema de clasificación multiclase.

En nuestro caso, al tratar de abordar un problema de multiclase, emplearemos la función de pérdida de Categorical Crossentropy.

4.2.4 OPTIMIZADOR

Al igual que la función de pérdida, el optimizador es el otro componente necesario para desarrollar y entrenar una red neuronal. Los optimizadores se encargan de modificar atributos como la tasa de aprendizaje tras cada época, asegurando que el aprendizaje es óptimo. A continuación, describiremos los principales optimizadores disponibles.

4.2.4.1 SGD

El primer optimizador es el optimizador SGD, stochastic gradient descent. Clásicamente ha sido el optimizador más típicamente usado en el desarrollo de las redes neuronales, y sigue los principios explicados en el apartado de aprendizaje de la red. Como tal, pues, es el optimizador más simple, y permite añadirle un grado de complejidad añadiendo momento, o impulso. El momento permite no solo que la red aprenda más rápido, sino que también permite amortiguar las posibles oscilaciones, y, por tanto, que la función alcance su mínimo global.

4.2.4.2 RMSprop

El optimizador RMSprop, como su nombre indica, aplica el algoritmo RMSprop, que se fundamenta en mantener una media móvil del cuadrado de los gradientes, y dividir el gradiente por la raíz de esa media. Además, el algoritmo mantiene la tasa de aprendizaje variable, y la optimiza época a época.

4.2.4.3 Adam

El tercer y último optimizador que se comentará es el optimizador Adam, uno de los algoritmos de optimización más populares actualmente.

El algoritmo Adam además de almacenar una media de los gradientes pasados al cuadrado, como RMSprop, también mantiene una media de los gradientes pasados que decae exponencialmente, y, por tanto, incorpora características similares al momento. Esto significa que empleando Adam se obtiene un optimizador que no solo proporciona una tasa de aprendizaje variable e inteligente, sino que también incorpora componentes de impulso. Por ello, y por su excelente rendimiento, será el optimizador que emplearemos en el entrenamiento de la red.

4.3 BATERÍA DE SEÑALES

Tras establecer los conceptos y fundamentos básicos que envuelven a las redes neuronales, antes de proceder a desarrollar y entrenar la red neuronal es necesario generar un conjunto de datos. Habitualmente, en el desarrollo de modelos de redes neuronales se parte de conjuntos de datos abiertos al público que simplifican el proceso de entrenamiento al asegurar un formato unificado y simplificado de datos. En nuestro caso, sin embargo, parte del interés del proyecto reside en la generación de una batería de entrenamiento adecuada, y otra batería de testing o evaluación. Previamente, se han comentado y explicado las diferentes modulaciones que se pretenden clasificar, y, a continuación, se comentarán los principios seguidos en la generación de las baterías de señales de entrenamiento y evaluación.

En primer lugar, cabe mencionar que la batería de entrenamiento será generada sin ruido, mientras que la batería de evaluación se generará con ruido. Por tanto, para establecer un umbral de ruido, se generarán varias baterías de señales de testing con diferentes valores de relación señal a ruido (SNR).

Por otro lado, la generación de señales será realizada de forma aleatoria siguiendo una distribución uniforme, de manera que el primer paso será la elección, de forma aleatoria, de una de las modulaciones. En función de la modulación escogida, existirán ciertos parámetros que se deberán establecer, los cuales procederemos a explicar.

En primer lugar, la modulación AM deberá escoger de forma aleatoria, mientras se sigue una distribución uniforme, el índice de modulación, estableciendo como posible valores 0,5 y 1.

La modulación FM, en cambio, escogerá el valor de la desviación de frecuencia, que afectará el ancho de banda de la señal, existiendo como posibles valores 0,5 y 0,8. En ambos casos,

tanto el índice de modulación AM, como el grado de desviación en FM, se han escogido estos valores por ser valores ampliamente usados en el ámbito de las comunicaciones.

Por otro lado, la modulación PSK variará dos parámetros: el índice de modulación PSK, que podrá variar entre 2 y 4, y el periodo de símbolo, que podrá tomar los siguientes valores: 16, 32, 64, 128 y 256. En el caso del índice de modulación, como se ha comentado anteriormente, se tratan de los dos valores de PSK más empleados, mientras que los valores de periodo de símbolo, de nuevo, son valores usados de manera extensa en el mercado.

En el caso de FSK únicamente se variará el periodo de símbolo, pudiendo usar los valores anteriormente mencionados.

En el caso de QAM, se deberán elegir dos diferentes parámetros. En primer lugar, se deberá elegir el índice de modulación QAM, el cual podrá ser 16 o 64. Los valores escogidos, al igual que las modulaciones anteriores, son valores usados extensamente en el mundo de las comunicaciones. Además, se deberá escoger el periodo de símbolo, el cual podrá variar entre los valores mencionados anteriormente: 16, 32, 64, 128 y 256.

Finalmente, en el caso de OFDM se mantendrá fijado el factor de utilización del espectro en un 80%, y se variará el periodo de símbolo entre los siguientes valores: 64, 128 y 256. Asimismo, el prefijo cíclico dependerá del periodo de símbolo, siendo siempre 1/8 del periodo de símbolo escogido.

Por último, se ha establecido una longitud de señal de 512 muestras, y el tamaño de la batería de entrenamiento será de 115.000 señales. Mientras tanto, las diferentes batería de testing generadas tendrán un tamaño de 25.000 señales, estableciendo por tanto un 82% de datos de entrenamiento, y un 18% de testing.

4.4 ENTRENAMIENTO DE LA RED

Tras haber desarrollado y creado una batería de señales variada y amplia, así como diferentes baterías de testing, el siguiente paso es el entrenamiento de la red.

Este paso nos permitirá diseñar una red neuronal potente y con amplia capacidad predictiva, y supondrá una primera visión acerca de su rendimiento. Por ello, en este caso no se evaluará la red con ninguna señal que tenga ruido, sino que se empleará la batería de entrenamiento, y parte de esa batería de entrenamiento se empleará como conjunto de validación, para ser exactos un 20% aleatorio del conjunto de datos.

Así pues, como se ha comentado anteriormente, partiendo de la batería de entrenamiento de 115.000 señales, el 20% de ella se empleará como batería de evaluación de la red. Dado que esta batería estará formada por muestras aleatorias, se implementará un random state, que asegure que, una vez escogidas las muestras de forma aleatoria, dicha batería de evaluación sea siempre la misma.

Por ello, se diseña la siguiente red para proceder al entrenamiento:

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 512)	262656
dense_1 (Dense)	(None, 256)	131328
dense_2 (Dense)	(None, 256)	65792
dense_3 (Dense)	(None, 256)	65792
dense_4 (Dense)	(None, 128)	32896
dense_5 (Dense)	(None, 64)	8256
dense_6 (Dense)	(None, 32)	2080
dense_7 (Dense)	(None, 6)	198

=====
 Total params: 568,998
 Trainable params: 568,998
 Non-trainable params: 0
 =====

Ilustración 15 - Diseño Red Neuronal

Como podemos ver, la red estará formada por una primera capa de 512 muestras, igual que la formada por las entradas, seguida de tres capas de 256 neuronas, una capa de 128 neuronas, una capa de 64 neuronas, una capa de 32 neuronas, y la capa final formada por 6 neuronas. En cuanto a las funciones de activación se refiere, se ha optado por la función Relu en todas las capas menos la última, en la cual se ha optado por la función softmax, al tratarse de un problema de clasificación multiclase. En el caso de las otras capas, se ha optado por la función Relu al ser la función más usada, y, debido al rendimiento mostrado en [5].

Una vez diseñada la red, se procede al entrenamiento de esta. Para ello, cabe mencionar que se ha optado por implementar un callback, que, como se indica en [10] es un tipo de función que permite detener el entrenamiento de una red neuronal. Para ello, se le añade un atributo que se debe monitorizar, en nuestro caso la pérdida en validación, y un número de épocas

tras el cual, si el valor que se está monitorizando no mejora, se detiene el entrenamiento. Es decir, si se implementa un callback que monitorice la pérdida en validación, y se le añade como atributo una paciencia de 5 épocas, se detendrá la red en caso de que, durante 5 épocas seguidas, la pérdida en validación no mejore. Una época es un periodo de tiempo por el cual se entrena la red con el conjunto de entrenamiento, es decir, cada vez que se alimenta la red con el conjunto de entrenamiento y la red aprende de él.

Los callbacks, además de ayudar en términos de eficiencia computacional, para que no se gasten recursos sin mejorar la red, permiten que la red no incurra en overfitting. El overfitting es un principio de las redes neuronales en el cual la red se sobre ajusta a los datos de entrenamiento del modelo, incluso aprendiendo del ruido de las señales, y su capacidad de generalización, y, por tanto, sus capacidades predictivas empeoran. Por ello, el callback es un componente muy útil y valioso, que nos permite de forma automática detener el entrenamiento sin incurrir en overfitting.

Finalmente, se establece como tamaño de lote, típicamente conocido como batch size, un tamaño de 32 muestras. El tamaño de lote es el número de muestras que la red analiza antes de actualizar sus parámetros, es decir, cada 32 muestras se actualizarán los pesos.

Teniendo todo lo anteriormente comentado en cuenta, se procede a entrenar la red, obteniendo los siguientes resultados en términos de pérdida en validación y entrenamiento, y precisión en entrenamiento y validación:




Ilustración 16 - Pérdidas en Entrenamiento y Validación (SNR = ∞)

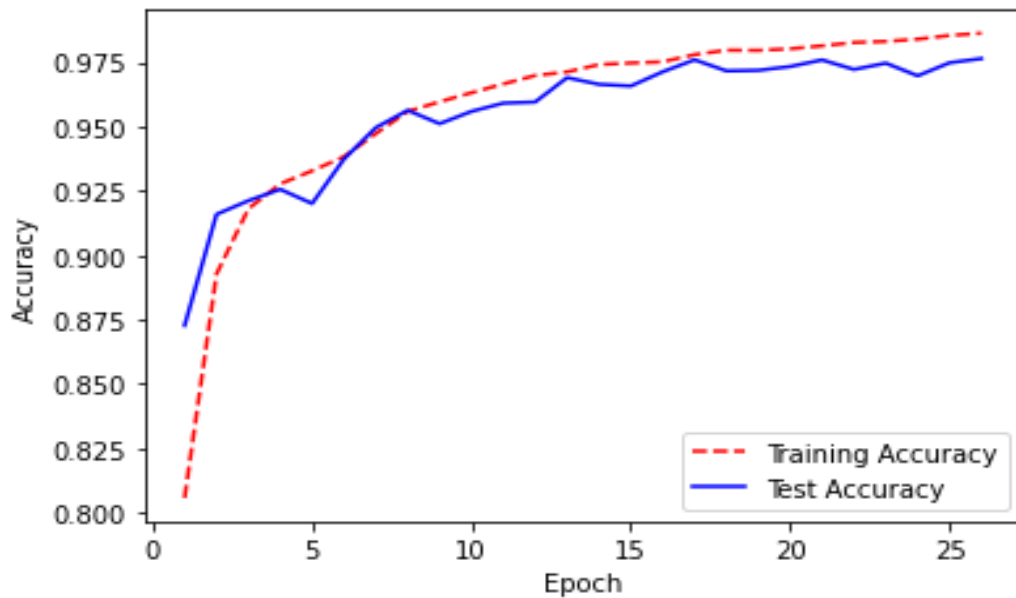


Ilustración 17 - Precisión en Entrenamiento y Validación (SNR = ∞)

Como podemos comprobar el rendimiento de la red ha sido excepcional, alcanzando una precisión en entrenamiento del 98,63%, y una precisión en validación del 97,64%. Además, podemos comprobar que el entrenamiento ha transcurrido durante 26 épocas, momento tras el cual se activó el callback y se detuvo el entrenamiento. Además, la pérdida, que recordamos que para el problema en cuestión era la el Categorical Crossentropy, alcanza unos valores de 0,038 en entrenamiento, y de 0,0915 en validación.

Pese a que los valores de precisión y pérdidas son excelentes, para obtener una visión real de las capacidades predictivas de la red, y de su rendimiento como tal, es necesario incrementar el grado de detalle con el que se analiza el rendimiento, analizando la capacidad de predicción de la red para las diferentes modulaciones. Para ello, pues, se debe obtener la visión que aporta la matriz de confusión, siendo esta la siguiente:

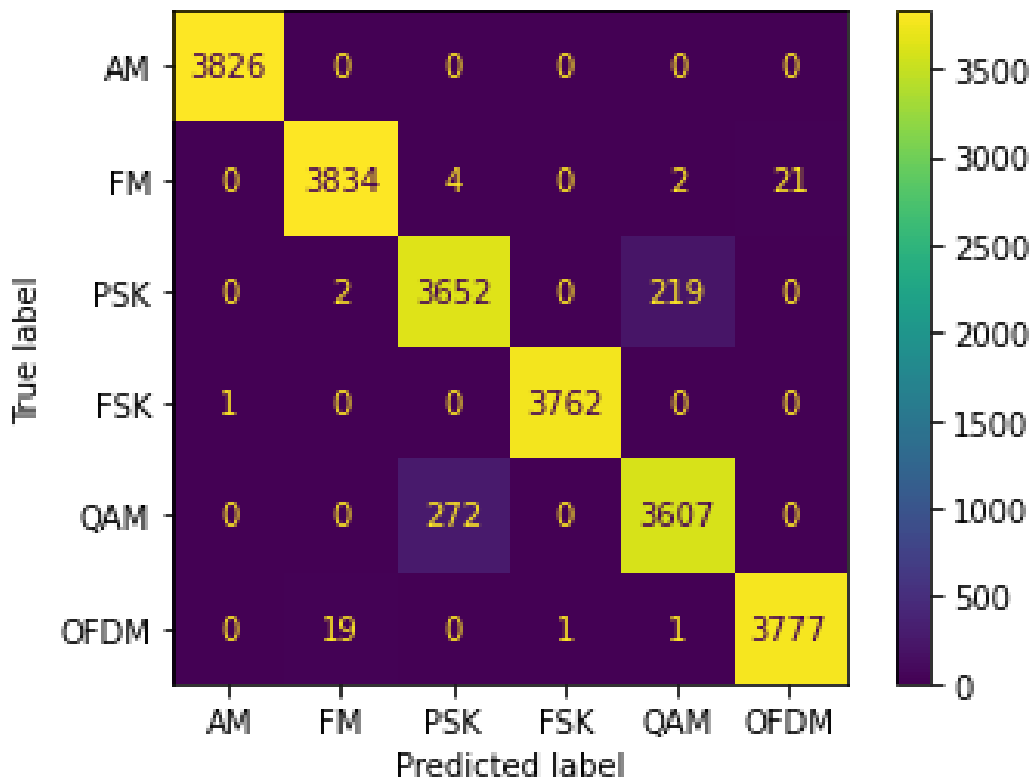


Ilustración 18 - Matriz de Confusión Absoluta (SNR = ∞)

A continuación, el rendimiento predictivo en formato de matriz de confusión en términos porcentuales:

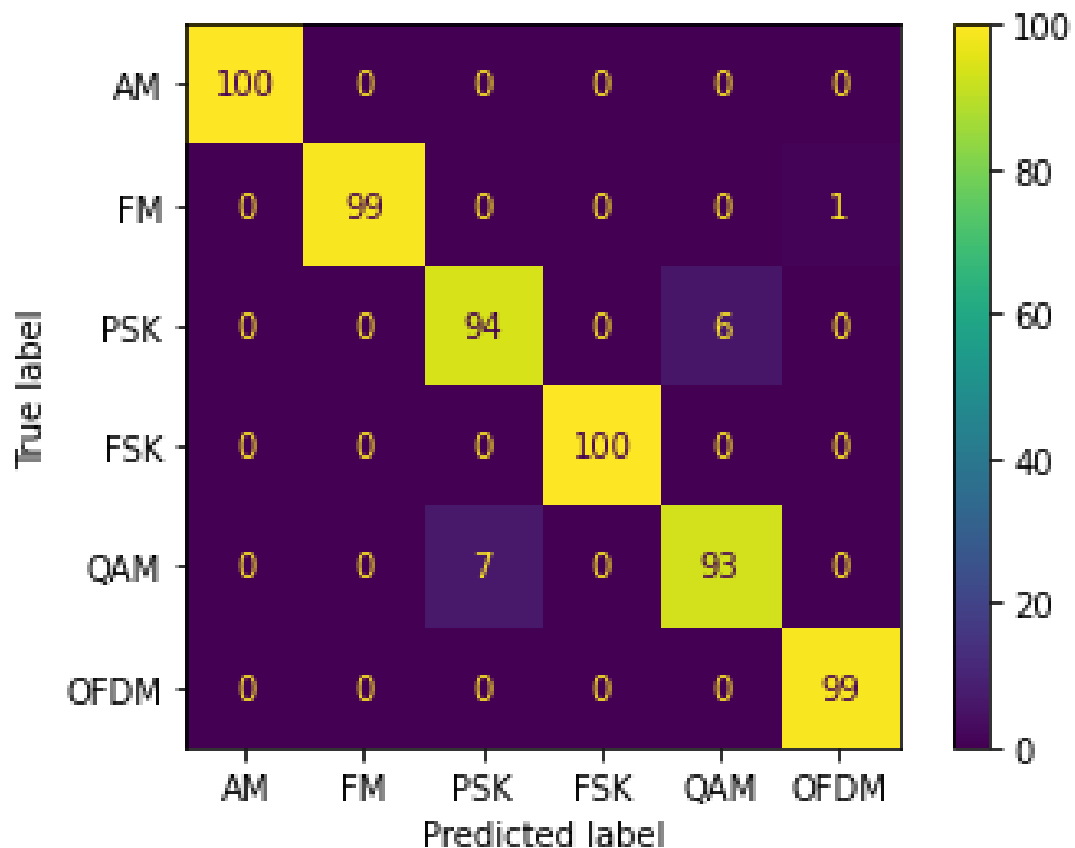


Ilustración 19 - Matriz de Confusión Porcentual (SNR = ∞)

De las matrices de confusión anteriormente mostradas podemos extraer una serie de conclusiones. En primer lugar, el rendimiento general de la red, y por tanto la valoración de sus capacidades predictivas, es excepcional, mostrando una precisión superior al 90% para los 6 tipos de modulaciones estudiadas. Por otro lado, se comprueba que la red es casi perfecta en la predicción de señales AM, FM, FSK y OFDM, mostrando que es claramente capaz de distinguir dichas modulaciones. Finalmente, se detecta que la única dificultad, siendo esta muy pequeña, es en la distinción de las señales PSK y QAM, mostrando una precisión del 94% y 93% respectivamente.

Tras haber constatado que la red muestra un gran comportamiento en un ámbito de condiciones ideales, es decir con un $\text{SNR} = \infty$, en el siguiente capítulo, de evaluación de resultados, se comprobará el rendimiento en condiciones más realistas, con diferentes niveles de ruido, y diferentes longitudes de señal.

Capítulo 5. EVALUACIÓN DE RESULTADOS

Tras haber realizado y analizado el entrenamiento de la red, concluyendo que el rendimiento es satisfactorio, es pertinente evaluar en mayor medida el rendimiento de la red que nos permita establecer umbrales de rendimiento adecuados.

A lo largo de este capítulo se evaluarán dos características del sistema clasificador. En primer lugar, se evaluará el comportamiento de la red frente a señales con diferentes relaciones de señal a ruido, ya que el entrenamiento se ha realizado sin ruido, es decir con una relación señal a ruido infinita. Por otro lado, en la práctica las señales tienen longitudes variables que no tienen por qué adecuarse a la longitud de entrada de nuestra red de 512 muestras, por lo que es de importancia crítica analizar el rendimiento del sistema de clasificación ante señales de mayor longitud.

5.1 RENDIMIENTO FRENTE AL RUIDO

En primer lugar, cabe mencionar que se ha empleado la red mostrada en Ilustración 15 empleando como conjunto de validación las señales con diferentes relaciones señal a ruido. Además, en todo caso se ha empleado un conjunto de validación formado por 25.000 muestras, para asegurar que las conclusiones que se extraen son precisas y validas. A continuación, se muestra el rendimiento de la red ante diferentes relaciones de señal a ruido, en orden decreciente.

5.1.1 SNR = 50 dB

En primer lugar, se analizará el rendimiento de la red frente a un conjunto de señales con relación señal a ruido de 50 dB. Al igual que en el entrenamiento de la red con señales sin ruido, se ha optado por un tamaño de lote, o batch size, de 32.

Tras entrenar la red, y evaluarla su rendimiento con señales con relación señal a ruido de 50 dB, se procede a obtener su matriz de confusión, que nos permitirá obtener una visión detallada del rendimiento del clasificador.

A continuación, mostramos la matriz de confusión obtenida en términos porcentuales:




Ilustración 20 - Matriz de Confusión Porcentual (SNR = 50dB)

Como se puede comprobar de la matriz de confusión obtenida, los resultados son muy buenos, alcanzando en todos los casos un nivel de precisión de alrededor del 85%. Además, se percibe que el rendimiento es especialmente notable para señales AM, FM, FSK y OFDM, con un nivel de precisión del 100%. Por otro lado, se percibe una ligera dificultad en la distinción entre señales PSK y QAM, algo que ya se podía percibir en el entrenamiento de

la red sin ruido. Aun así, pese a obtener un nivel de precisión ligeramente inferior al de las señales moduladas en AM, FM, FSK y OFDM, la precisión mostrada en la clasificación de señales PSK y QAM es satisfactoria, siendo cercana o superior al 85%.

Finalmente, a nivel global se ha obtenido una probabilidad de correcta clasificación del 95,22%, un valor que muestra el excelente rendimiento logrado por la red a nivel general.

Por tanto, se puede comprobar que la red se comporta de manera excelente ante señales con relación señal a ruido de 50dB, por lo que se evaluará su rendimiento para señales con mayores niveles de ruido.

5.1.2 SNR = 40 dB

De nuevo, se han empleado los mismos parámetros que en el caso anterior, para asegurar homogeneidad, y, por tanto, que las conclusiones extraídas son válidas.

Al igual que en el caso anterior, partiendo del entrenamiento de la red con un conjunto de training formado por señales con relación señal a ruido infinita, se procede a evaluar la probabilidad de clasificación correcta para señales con relación señal a ruido de 40 dB.

A continuación, podemos comprobar la matriz de confusión basado en las predicciones de la red:

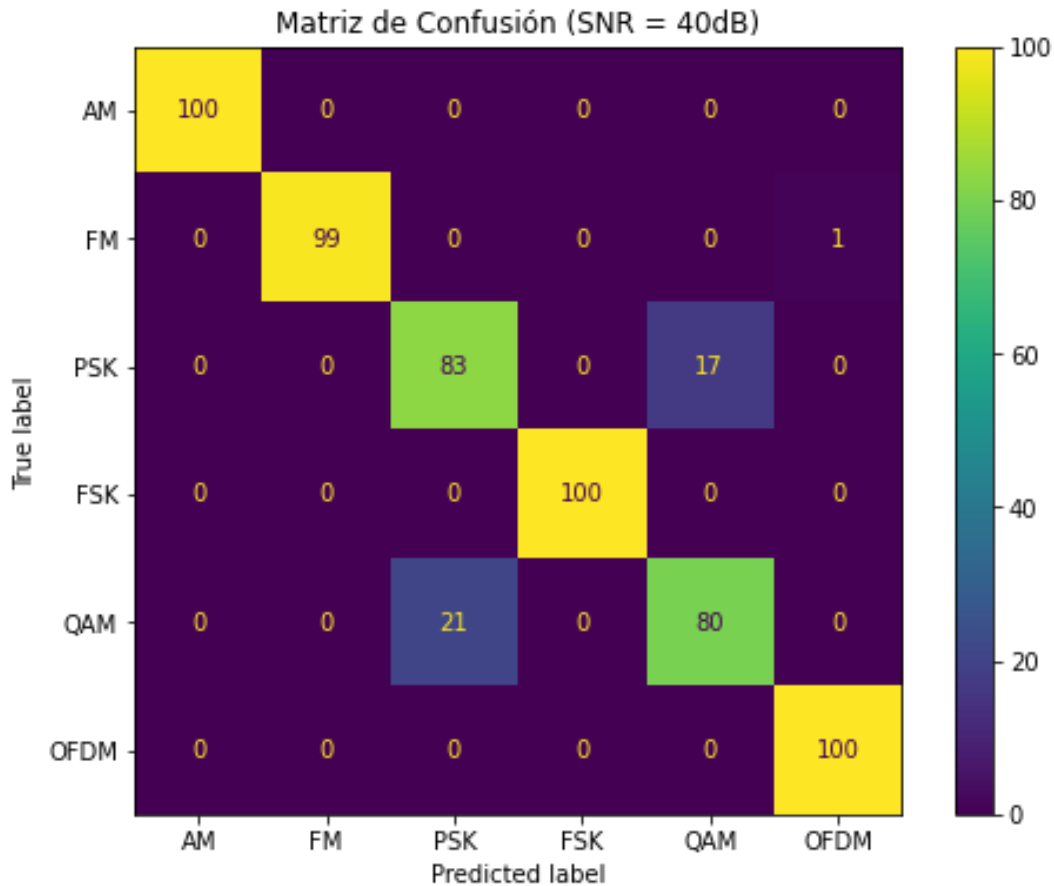


Ilustración 21 - Matriz de Confusión Porcentual (SNR = 40dB)

De la Ilustración 21 podemos comprobar que, de nuevo, el rendimiento de la red es excepcional. Si bien la red se comporta ligeramente peor que con señales de SNR = 50dB, como es de esperar, las diferencias son mínimas, únicamente empeorando la precisión en señales PSK desde un 88% a un 83%, y en las señales QAM descendiendo la precisión de un 84% a un 80%. Para el resto de las señales, únicamente se disminuye la probabilidad de correcta clasificación para señales moduladas en FM, siendo este cambio mínimo, ya que se desciende de un 100% de precisión a un 99%. En el caso de las señales AM, FSK y OFDM los valores de precisión son iguales que los obtenidos con SNR = 50dB, obteniendo en todo caso valores de precisión del 100%.

Por otro lado, en términos de clasificación global se obtiene una probabilidad de correcta clasificación del 93,5%, ligeramente inferior a la obtenida para señales de 50 dB, que era del 95,22%. Aun así, obtener un valor de precisión del 93,5% es un resultado excelente, y, por tanto, se puede considerar satisfactorio el rendimiento del clasificador.

Por tanto, dado que los resultados obtenidos son satisfactorios, se va a continuar a evaluar la red con conjuntos de datos formados por señales con mayor ruido, para así poder establecer un umbral de ruido que asegure un rendimiento de la red aceptable.

5.1.3 SNR = 30 dB

Tras haber analizado el rendimiento de la red frente a señales con niveles de relación señal a ruido de 50 dB y 40 dB, y haber comprobado que el rendimiento es satisfactorio, procederemos a estudiar el rendimiento para señales con SNR de 30 dB.

De nuevo, partiendo del entrenamiento de la red con un conjunto de training formado por señales con relación señal a ruido infinita, se procede a evaluar la probabilidad de clasificación correcta para señales con relación señal a ruido de 30 dB.

Teniendo esto en cuenta, comprobaremos en mayor detalle el comportamiento de la red analizando la matriz de confusión resultante de las predicciones de la red:




Ilustración 22 - Matriz de Confusión Porcentual (SNR = 30dB)

Como se preveía el rendimiento de la red es excelente, mostrando niveles de precisión superiores al 99% en todos los casos salvo para la modulación PSK y QAM. De nuevo, la única dificultad que encuentra la red reside en la distinción de las señales QAM y PSK, pero, aun así, el rendimiento general es satisfactorio.

Además, cabe remarcar que las precisiones obtenidas para cada modulación son iguales a las obtenidas cuando se ha evaluado la red con señales con relación señal a ruido de 40 dB. Esto nos da a indicar la robustez que muestra la red, y sus excelentes capacidades de abstracción.

En términos globales, la probabilidad de correcta clasificación es del 93,62%, un valor ligeramente superior al obtenido con señales de SNR = 40dB, y, que, por tanto, nos denota el excelente rendimiento de la red.

Por tanto, tras constatar que el rendimiento de la red es satisfactorio, evaluaremos las predicciones para señales con mayor ruido.

5.1.4 SNR = 20 dB

Tras haber conseguido resultados aceptables para valores de relación señal a ruido superiores, se comprobará el rendimiento de la red para SNR = 20 dB.

Para ello, a continuación, mostramos la matriz de confusión porcentual derivada de las predicciones de la red para señales con relación señal a ruido de 20 dB:




Ilustración 23 - Matriz de Confusión (SNR = 20dB)

De la anterior ilustración, podemos comprobar que el rendimiento es excepcional. De hecho, paradójicamente, hasta el momento la red muestra una mayor capacidad de clasificación para señales con SNR = 20 dB. Al igual que con las matrices de confusión mostradas anteriormente, para diferentes niveles de ruido, la red realiza un gran trabajo de predicción para señales de AM, FM, FSK y OFDM, alcanzando una precisión del 100%. Además, para señales PSK y QAM la red muestra una gran solidez, alcanzando una precisión del 90% para señales PSK y del 87% para señales QAM.

Finalmente, a nivel global, se alcanza una probabilidad de correcta clasificación del 96%, el valor más alto obtenido hasta el momento. Esto nos da a indicar que para toda señal con una

relación señal a ruido superior a 20 dB el clasificador va a realizar un excelente trabajo, y va a mostrar una gran probabilidad de clasificación correcta.

Así pues, podemos afirmar que el rendimiento de la red es claramente satisfactorio, y, por tanto, se va a proceder a evaluar la red con señales con mayores niveles de ruido.

5.1.5 SNR = 10 dB

Tras haber evaluado el rendimiento de la red para señales con niveles de relación señal a ruido de 20 dB, y haber mostrado un gran rendimiento, procederemos a evaluar el rendimiento de la red frente a señales de relación señal a ruido de 10 dB.

Para poder comprobar más extensamente, y en mayor detalle, el rendimiento mostrado por la red es necesario obtener una visión a nivel de cada modulación. Por ello, a continuación, se muestra la matriz de confusión obtenida de las predicciones de la red:

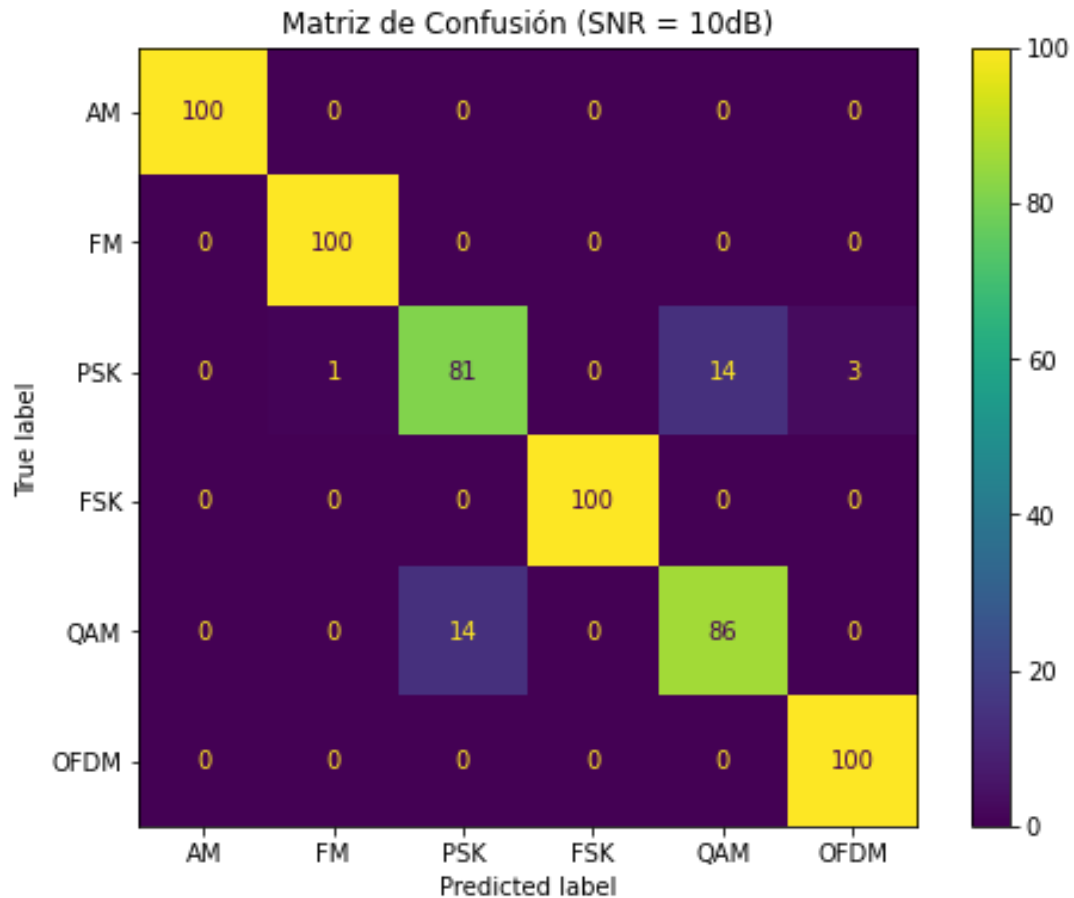


Ilustración 24 - Matriz de Confusión Porcentual (SNR = 10dB)

De la matriz de confusión obtenida se puede denotar que el rendimiento, pese a seguir siendo bueno, es ligeramente inferior a mostrado en la clasificación de señales con relación señal a ruido de 20 dB. Pese a ello, el clasificador continúa alcanzando niveles de precisión del 100% para señales moduladas en AM, FM, FSK y OFDM. En el caso de señales moduladas en QAM y PSK el rendimiento es ligeramente inferior, pese a lo cual se logra alcanzar un nivel de precisión del 81% y 86% respectivamente.

En términos globales, se logra una probabilidad de correcta clasificación del 94,35%, un valor que, pese a ser ligeramente inferior al obtenido con señales de SNR = 20 dB, es plenamente aceptable, y demuestra el gran rendimiento del clasificador.

En todo caso, pese que el rendimiento ha disminuido ligeramente, obtener valores de precisión en validación cercanos o superiores al 80% en todas las modulaciones sigue siendo un muy buen resultado. Por ello, se va a comprobar el rendimiento de la red para señales con relación señal a ruido de 5 dB, para así poder determinar un umbral de rendimiento frente al ruido eficaz y preciso.

5.1.6 SNR = 5 dB

Para poder establecer un umbral de rendimiento de la red frente al ruido, se debe establecer un valor mínimo de relación señal a ruido. Para ello, analizaremos el rendimiento de la red para un conjunto de evaluación formado por señales con SNR = 5 dB.

Así pues, para obtener una visión detallada del rendimiento del clasificador, a continuación, mostramos la matriz de confusión obtenida de las predicciones de la red neuronal:

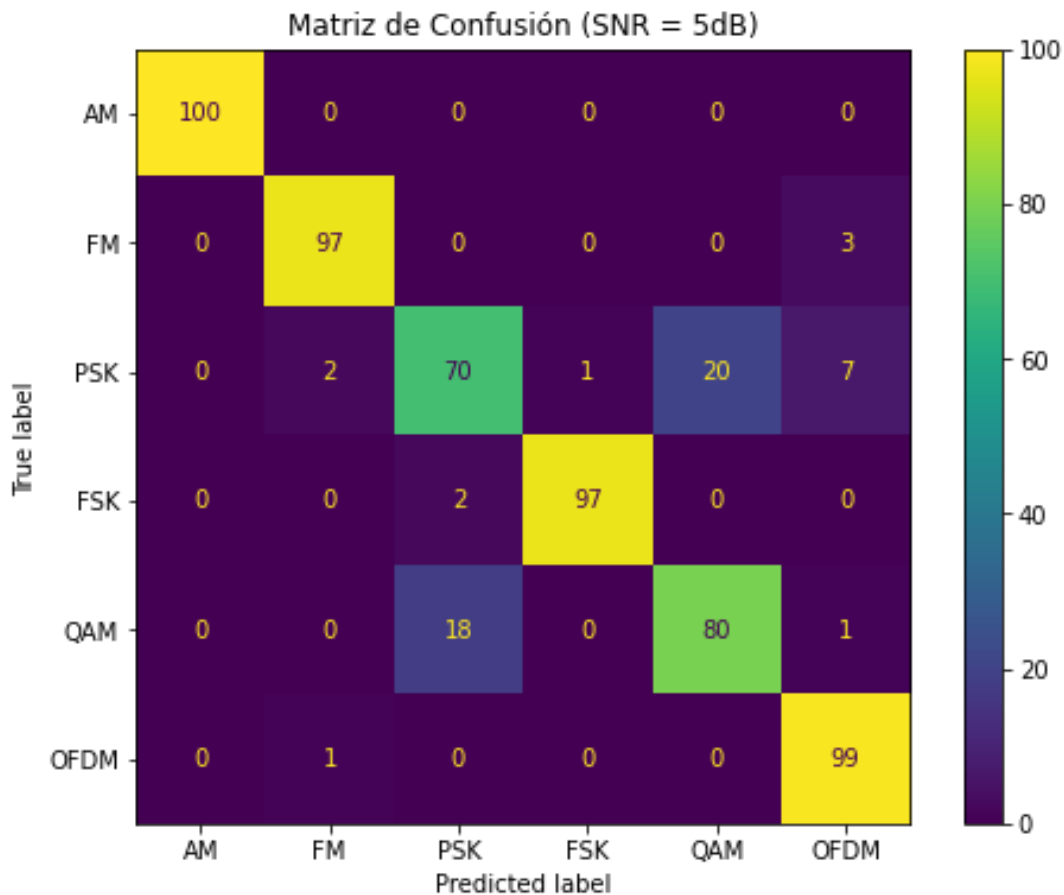


Ilustración 25 - Matriz de Confusión Porcentual (SNR = 5dB)

De la Ilustración 25 podemos comprobar que, como preveíamos, el rendimiento es inferior al mostrado para niveles de relación señal a ruido superiores.

Como podemos comprobar, los valores de precisión para señales AM, FM, FSK y OFDM siguen siendo excelentes, alcanzando niveles de precisión del 100%, 97%, 97% y 99% respectivamente. En cambio, para las señales moduladas en PSK y QAM se denota una ligera pérdida de rendimiento, logrando niveles de precisión del 70% y 80% respectivamente. A modo ilustrativo, para las señales con SNR de 10 dB los niveles de precisión en señales PSK y QAM eran del 81% y 86% respectivamente. Por tanto, dada la disminución en los niveles de precisión de dichas señales, podemos considerar que se ha alcanzado el umbral de rendimiento frente al ruido deseado.

En términos generales se alcanza una probabilidad de correcta clasificación del 90,48%, un valor que, pese a ser inferior al logrado para mayores niveles de ruido, demuestra el excelente rendimiento de la red a nivel general.

5.2 SEÑALES DE MAYOR LONGITUD

En la práctica, los sistemas clasificadores automáticos de modulaciones no trabajan en condiciones ideales, y, por tanto, ser capaz de predecir el comportamiento del sistema en dichas condiciones, y, consecuentemente, el rendimiento del sistema es de vital importancia para poder evaluar el éxito del proyecto.

Por tanto, al igual que era crítico evaluar la tolerancia al ruido, que nos permita establecer un umbral de rendimiento frente al ruido, es pertinente evaluar el comportamiento del sistema frente a señales de mayor tamaño. En este sentido, las señales de comunicaciones no tienen por qué ser de 512 muestras, como las que hemos empleado para entrenar la red, por lo que es preciso evaluar la respuesta del sistema ante señales de mayor longitud.

Así pues, en los subapartados que conforman este capítulo se evaluará la respuesta del sistema ante señales de diferente longitud. Para ello, cabe recordar el sistema mostrado en la Ilustración 3, cuyos conceptos se emplearán evaluar la respuesta del sistema. Así pues, en primer lugar, se segmentarán las señales en tantos fragmentos de 512 muestras como sea posible. Posteriormente, cada fragmento será evaluado por la red neuronal, y se generará una predicción para cada fragmento, que será emplazada en un buffer hasta que todos los fragmentos hayan sido evaluados. Finalmente, se aplicará una regla de máximos para así determinar la predicción de la señal completa.

Así pues, teniendo lo anteriormente comentado en mente, en los siguientes subapartados se procede a evaluar la respuesta del sistema para señales de diferentes longitudes. Dichas longitudes serán escogidas en función de su popularidad en el ámbito de las comunicaciones, es decir, se estudiarán longitudes de señal ampliamente usadas.

5.2.1 SEÑALES DE LONGITUD 2048

En primer lugar, se analizará la respuesta del sistema clasificador ante señales de longitud 2048 muestras. Como se puede prever, una señal de 2048 muestras genera 4 fragmentos de 512 muestras, cada uno de los cuales será clasificado de forma independiente. Además, para el análisis se va a partir de una relación señal a ruido de 20 dB, un valor de SNR medio de los estudiados anteriormente, y, que nos permitirá obtener una visión general de la respuesta del sistema ante señales de mayor longitud.

Así pues, a continuación, mostramos la matriz de confusión derivada de las predicciones de la red para la señal completa:

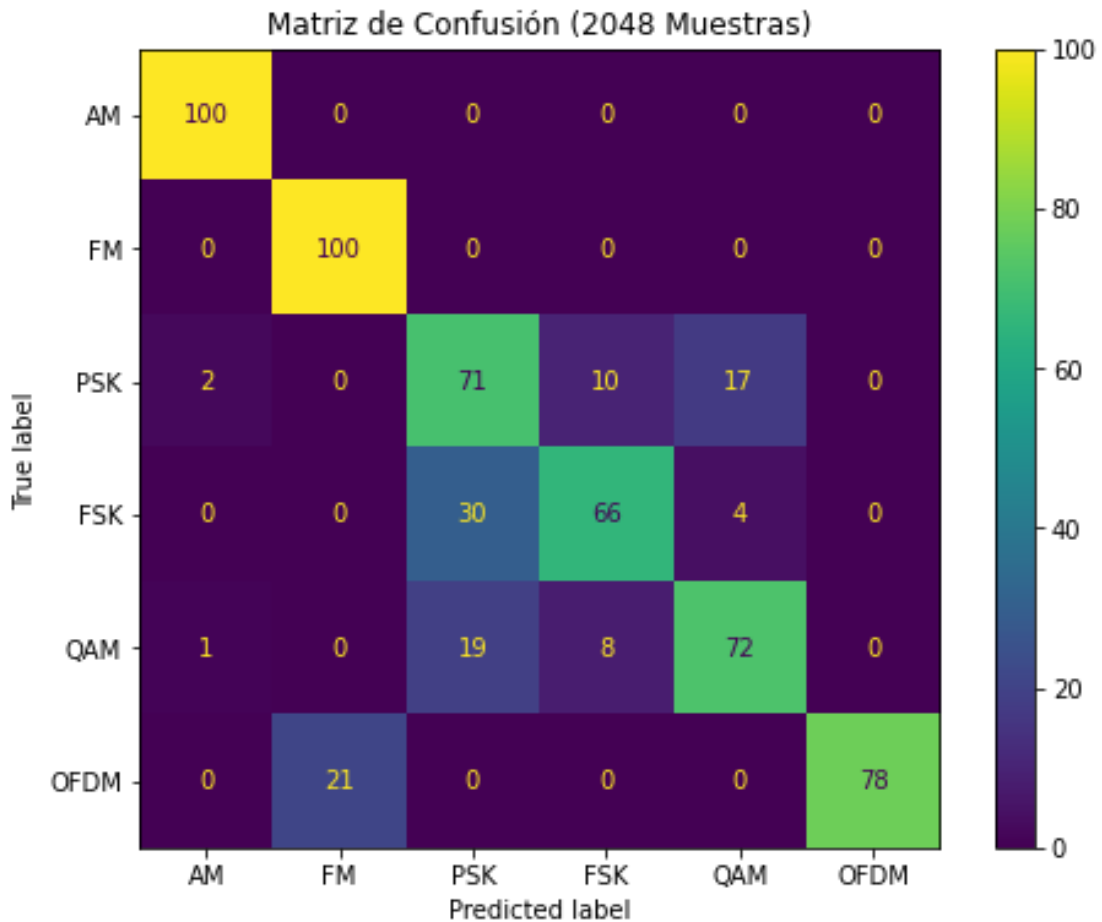


Ilustración 26 - Matriz de Confusión Señal de Longitud 2048 (SNR = 20dB)

Como se puede comprobar de la Ilustración 26, el resultado, pese a no ser excelente, se puede considerar como aceptable. En cuanto a las modulaciones AM y FM se alcanzan niveles de precisión del 100%, mientras que para las modulaciones PSK, QAM y OFDM se logran niveles de precisión superiores al 70%. Finalmente, las señales FSK muestran una probabilidad de correcta clasificación del 66%, el único caso en el que la precisión es inferior al 70%.

A nivel general, la probabilidad de correcta clasificación alcanzada es del 81,1%, un valor, que, pese a ser claramente inferior al mostrado con 512 muestras, se puede considerar aceptable.

Así pues, el rendimiento es inferior que el mostrado para señales de 512 muestras, algo que era de esperar. Más aun, dado que solo tenemos 4 fragmentos de 512 muestras, una predicción errónea tiene un impacto mucho mayor. Por ello, es de prever que el rendimiento será mucho mejor para señales con mayor longitud, lo cual se comprobará en los siguientes subapartados.

5.2.2 SEÑALES DE LONGITUD 4096

Tras analizar el rendimiento del sistema clasificador frente a señales de longitud de 2048 muestras, procederemos a estudiar la respuesta del sistema ante señales de longitud de 4096 muestras, un tamaño estándar en el ámbito de las comunicaciones. Al igual que en el caso anterior, las señales muestran una relación señal a ruido de 20 dB.

A continuación, se muestra la matriz de confusión derivada de las predicciones de la red para la señal completa de 4096 muestras:

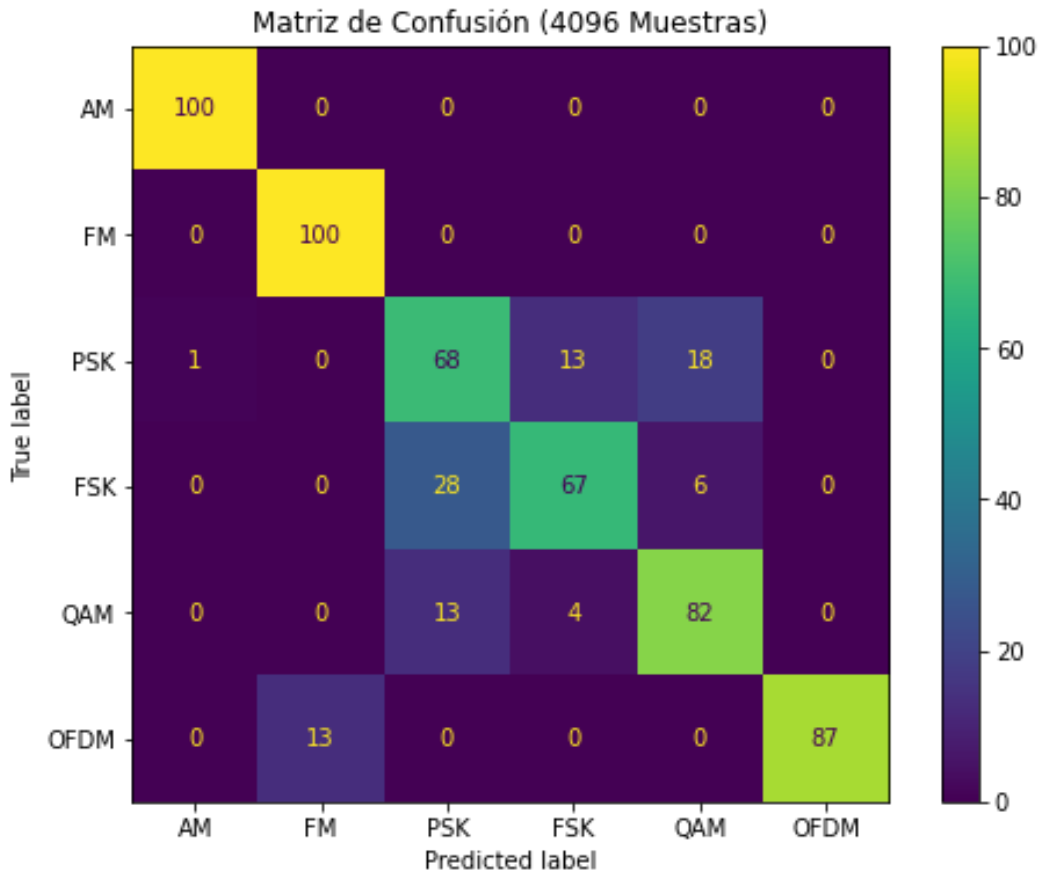


Ilustración 27 - Matriz de Confusión Señal de Longitud 4096 (SNR = 20dB)

Como se puede comprobar, el rendimiento de la red ha sido superior al mostrado para señales de 4096 muestras.

Tal y como preveíamos, a medida que aumentan el número de fragmentos de 512 muestras a clasificar, el error de clasificación por cada fragmento tiene un impacto mucho menor, y, por tanto, la clasificación global tiende a alcanzar niveles de precisión más elevados. Así, se puede comprobar que la precisión en señales QAM se ha incrementado de un 72% a un 82%, mientras que para señales OFDM ha pasado de niveles de precisión del 78% al 87%.

Aun así, se sigue notando una cierta debilidad en la clasificación de señales PSK y FSK, que muestran una precisión del 68% y 67% respectivamente. Pese a ser un valor inferior al

mostrado en las señales de 512 fragmentos, valores de precisión cercanos al 70% se pueden considerar aceptables.

En todo caso, el rendimiento general es excelente, alcanzando niveles de precisión global de un 85%. Por tanto, se puede concluir que la red responde de forma satisfactoria ante señales de longitud de 4096 muestras.

Capítulo 6. CONCLUSIONES Y TRABAJOS FUTUROS

El presente trabajo ha supuesto una primera aproximación al desarrollo de un sistema clasificador automático de modulaciones. Como se ha comentado, el estado de la cuestión actual concierne el desarrollo de redes neuronales profundas, principalmente redes neuronales convolucionales (CNN) o redes neuronales residuales (Resnet), las cuales requieren un grado de conocimiento previo elevado.

En cambio, las redes neuronales artificiales son redes neuronales más simples basadas en la estructura del perceptrón multicapa, que no requieren un gran conocimiento previo, ni conceptual ni matemático. Así pues, con el desarrollo de este trabajo se pretende estudiar la viabilidad de las redes neuronales artificiales como sistema clasificador automático de modulaciones, y sus posibles limitaciones.

Para ello, se ha comenzado por realizar un estudio de las diferentes modulaciones que se pretenden clasificar, permitiendo así generar una amplia batería de señales con las que entrenar y evaluar el sistema clasificador. Tras diseñar el código de las diferentes modulaciones se ha generado una batería de entrenamiento y otra de evaluación con variaciones aleatorias en los diferentes parámetros de cada modulación.

Así pues, con la batería de señales generada, se ha procedido a desarrollar y entrenar un red neuronal empleando únicamente señales sin ruido, es decir con niveles de relación señal a ruido infinita. Tras constatar que el rendimiento de la red lidiando con señales sin ruido era excepcional, se ha procedido a estudiar el impacto de la relación señal a ruido en el rendimiento de la red, analizando la precisión de la red para diferentes niveles de SNR.

A continuación, mostramos una figura elaborada con los diferentes niveles de precisión obtenidos en validación para cada valor de SNR diferente:

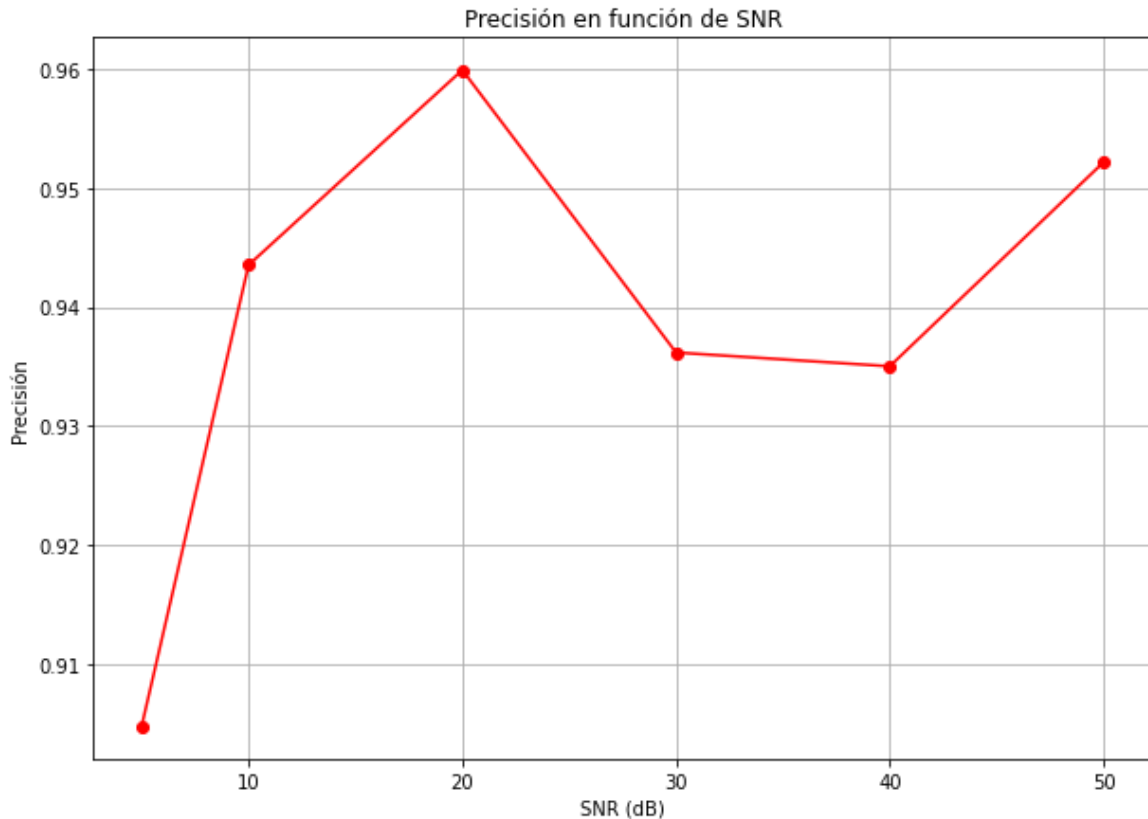


Ilustración 28 - Precisión en función de SNR

De la anterior figuras, podemos comprobar que la relación señal a ruido tiene un impacto sustancialmente mayor a medida que la relación señal a ruido se hace menor. Como se puede comprobar, la precisión disminuye levemente en niveles altos de SNR, y comienza a disminuir en mayor medida cuando existe un nivel de ruido considerable. Aun así, se logra alcanzar una probabilidad de correcta clasificación superior al 90% en todos los valores de SNR estudiados, lo cual muestra la robustez del clasificador.

En todo caso, el rendimiento en todos los casos es más que satisfactorio, mostrando unos niveles de precisión excelentes, y pérdidas poco significativas. Para analizar en mayor detalle el rendimiento de la red, se muestra una tabla resumen con las precisiones para cada modulación en función de los valores SNR:

Modulación	SNR (dB)					
	50 dB	40 dB	30 dB	20 dB	10 dB	5 dB
AM	100%	100%	100%	100%	100%	100%
FM	100%	99%	99%	100%	100%	97%
PSK	88%	83%	83%	90%	81%	70%
FSK	100%	100%	100%	100%	100%	97%
QAM	84%	80%	80%	87%	86%	80%
OFDM	100%	100%	100%	100%	100%	99%

Tabla 4 - Resumen Precisión en función SNR

Al igual que la precisión global era excelente para los diferentes valores de relación señal a ruido, de la anterior table podemos denotar que, ahondando en un mayor grado de detalle los resultados son igual de satisfactorios. En primer lugar, es de remarcar que para las modulaciones AM, FM, FSK y OFDM, se alcanzan niveles de precisión superiores al 95% en todos los casos, y en su mayoría cercanos al 100%. En cambio, la clasificación para las modulaciones PSK y QAM es la que mayor grado de dificultad ha mostrado. Pese a ello, en el caso de QAM los niveles de precisión alcanzados son en todo caso superiores al 80%, mientras que en el caso de PSK, se denotan dificultades únicamente en valores de SNR = 5 dB, alcanzando un nivel de precisión del 70%.

Por tanto, tras establecer un umbral de rendimiento frente al ruido satisfactorio, el ultimo análisis ha consistido en evaluar la clasificación de señales de mayor longitud. Para ello, se ha evaluado el rendimiento de la red frente a señales de 2048 y 4096 muestras, mostrando los siguientes resultados:

<i>Modulación</i>	<i># Muestras</i>	
	2048	4096
AM	100%	100%
FM	100%	100%
PSK	71%	68%
FSK	66%	67%
QAM	72%	82%
OFDM	78%	87%

Tabla 5 - Resumen Precisión en función de Tamaño

Al igual que para los diferentes valores de relación señal a ruido, la introducción de señales con diferentes longitudes ha mostrado resultados satisfactorios. En este caso, se puede denotar el impacto de la longitud de señal, ya que un error de clasificación de un fragmento tiene un impacto mucho mayor en señales con 2048 muestras comparado con el impacto en las señales de 4096 muestras. Pese a ello, alcanzar niveles de precisión superiores al 65% se puede considerar como un resultado aceptable, alcanzando además una precisión superior al 80%. Mientras tanto, en el caso de las señales de 4096 muestras se consiguen precisiones superiores o cercanas al 70% en todas las modulaciones, y se alcanza una precisión global del 85%.

Con todo ello, tras evaluar el sistema clasificador se puede concluir que existe viabilidad para implantar una red neuronal artificial como sistema clasificador automático de modulaciones, mostrando una adecuada tolerancia al ruido, y una aceptable adaptación a diferentes tamaños de señal. Aun así, se puede ahondar en mayor grado de detalle buscando líneas alternativas de trabajo. Entre dichos posibles trabajos futuros destacamos los siguientes:

- Inclusión de nuevas modulaciones y mayor grado de variabilidad de parámetros de modulación

- Estudio del rendimiento del sistema clasificador para señales con diferentes desviaciones de frecuencia
- Análisis exhaustivo de señales de diferentes longitudes implementando un algoritmo de clasificación de fragmentos diferente a la regla de máximos
- Implementación de sistemas clasificadores basados en redes neuronales profundas, como redes neuronales convolucionales (CNN) o redes neuronales residuales (Resnet)

Capítulo 7. BIBLIOGRAFÍA

- [1] Azzouz, E., & Nandi, A. K. (2013). Automatic modulation recognition of communication signals.

- [2] Barrero, Giovanni. (2018). PREDICCIÓN DE LA CALIDAD DE SOFTWARE DESARROLLADO EN IBM RPG USANDO DEEP LEARNING.

- [3] Bliudze, Simon & Billy, Nicolas & Krob, Daniel. (2005). On optimal hybrid ARQ control schemes for HSDPA with 16QAM. 121 - 127 Vol. 1. 10.1109/WIMOB.2005.1512826.

- [4] Datta, Leonid. (2020). A Survey on Activation Functions and their relation with Xavier and He Normal Initialization.

- [5] Dubey, A.K., Jain, V. (2019). Comparative Study of Convolution Neural Network's Relu and Leaky-Relu Activation Functions. In: Mishra, S., Sood, Y., Tomar, A. (eds) Applications of Computing, Automation and Wireless Systems in Electrical Engineering. Lecture Notes in Electrical Engineering, vol 553. Springer, Singapore. https://doi.org/10.1007/978-981-13-6772-4_76

- [6] Durán, J. (2021, 11 diciembre). Todo lo que Necesitas Saber sobre el Descenso del Gradiente Aplicado a Redes Neuronales. Medium. <https://medium.com/metadatos/todo-lo-que-necesitas-saber-sobre-el-descenso-del-gradiente-aplicado-a-redes-neuronales-19bdbb706a78>

- [7] Emam, A., Shalaby, M., Mansour, H.A., Bakr, H.E., & Aboelazm, M.A. (2020). An optimized Radio Modulation Classifier Using Deep Neural Network. 2020 12th International Conference on Electrical Engineering (ICEENG), 175-180.
- [8] Frequency Shift Keying. (2022). TutorialsPoint. https://www.tutorialspoint.com/digital_communication/digital_communication_frequency_shift_keying.htm
- [9] Hassan, Kais & Dayoub, Iyad & Hamouda, Walaa & Berbineau, Marion. (2010). Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems. EURASIP Journal on Advances in Signal Processing. 2010. 42. 10.1155/2010/532898.
- [10] Hinno, R. (2021, 23 diciembre). Callbacks in neural networks - Towards Data Science. Medium. <https://towardsdatascience.com/callbacks-in-neural-networks-b0b006df7626>
- [11] Hong, Liang & Ho, K.. (2000). BPSK and QPSK Modulation classification with unknown signal level. 2. 976 - 980 vol.2. 10.1109/MILCOM.2000.904076.
- [12] Huan, C., & Polydoros, A. (1995). Likelihood methods for MPSK modulation classification. IEEE Trans. Commun., 43, 1493-1504.
- [13] Lázaro, M. & Open Course Ware (OCW). (2014). Teoría de la Comunicación. UC3M.
- [14] Mahdiraji, Ghafour Amouzad & Abas, Ahmad Fauzi. (2010). Advanced Modulation Formats and Multiplexing Techniques for Optical Telecommunication Systems. 10.5772/8494.

- [15] Meng, Fan & Chen, Peng & Wu, Lenan & Wang, Xianbin. (2018). Automatic Modulation Classification: A Deep Learning Enabled Approach. *IEEE Transactions on Vehicular Technology*. 67. 10760-10772. 10.1109/TVT.2018.2868698.
- [16] Ouahada, Khmaies & Ferreira, Hendrik & Vinck, Jan & Snyders, A.J. & Swart, Theo. (2007). Cancellation and error correction for narrowband interference with spectral nulls codes and OFDM modulation. 1-7. 10.1109/AFRCON.2007.4401559.
- [17] Panagiotou, Prokopios & Anastasopoulos, Achilleas & Polydoros, Andreas. (2000). Likelihood Ratio Tests for Modulation Classification. 2. 670 - 674 vol.2. 10.1109/MILCOM.2000.904013.
- [18] Ramjee, S., Ju, S., Yang, D., Liu, X., Gamal, A.E., & Eldar, Y.C. (2019). Fast Deep Learning for Automatic Modulation Classification. *ArXiv*, abs/1901.05850.
- [19] Sharma, Deepak & Kumar, Suresh. (2017). An Overview of Elastic Optical Networks and its Enabling Technologies. *International Journal of Engineering and Technology*. 9. 1643-1649. 10.21817/ijet/2017/v9i3/170903022.
- [20] Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12), 310-316.
- [21] Soliman, Samir & Hsue, S.-Z. (1992). Signal Classification Using Statistical Moments. *Communications, IEEE Transactions on*. 40. 908 - 916. 10.1109/26.141456.
- [22] Wei, Wen & Mendel, Jerry. (2000). Maximum-likelihood classification for digital amplitude-phase modulations. *Communications, IEEE Transactions on*. 48. 189 - 193. 10.1109/26.823550.

- [23] Wikipedia contributors. (2022, 24 junio). Sigmoid function. Wikipedia.
https://en.wikipedia.org/wiki/Sigmoid_function
- [24] Zhu, Z., & Nandi, A. K. (2015). Automatic Modulation Classification: Principles, Algorithms and Applications. Wiley.

ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS

Los Objetivos de Desarrollo Sostenible (ODS) son un conjunto de objetivos propuestos por las Organización de las Naciones Unidas (ONU) en 2015 con el objetivo de promover la protección y sostenibilidad del planeta, erradicar la pobreza mundial y garantizar la prosperidad y paz mundial para el año 2030. Así pues, se diseñaron 17 objetivo integrados que buscan involucrar a gobiernos, empresas, y a la sociedad para alcanzar las metas especificadas.

De los 17 objetivos enumerados por la ONU, este proyecto aplica principalmente a los siguientes:

- Industria innovación y arquitectura
- Producción y consumo responsables
- Trabajo decente y crecimiento económico

El primer objetivo al que se contribuye por medio de este proyecto es Industria, innovación y arquitectura, que se centra en construir infraestructuras resilientes, promover la industrialización sostenible y fomentar la innovación. En este caso, a través del desarrollo de un sistema clasificador automático de modulaciones, se promueve la innovación, y se permite dedicar los recursos ahorrados a otras labores más eficientes.

Así pues, dado que los sistema clasificadores automáticos de modulaciones son una manera más eficiente de clasificar modulaciones frente a los métodos usados más típicamente, los clasificadores basados en características, mediante el desarrollo de un clasificador automático de modulaciones se promueve también el objetivo de producción y consumo

responsables. Los clasificadores basados en características son métodos computacionalmente costosos y poco eficientes, siendo los clasificadores automáticos una alternativa más eficiente en términos computacionales, y por tanto en términos de electricidad y energía.

Finalmente, dado que mediante la implantación de un clasificador automático de modulaciones se consigue un ahorro de recursos tanto energéticos o computacionales como en términos de tiempo dedicado por personas a la clasificación de modulaciones, estos recursos ahorrados pueden dedicarse a otras áreas o industrias en desarrollo. Por tanto, de manera indirecta se promoviendo el trabajo decente y el crecimiento económico.

En definitiva, los Objetivos de Desarrollo Sostenible son un programa integral con la ambición para solucionar los grandes problemas que afectan a la humanidad y al planeta, y, por tanto, la consecución de dichos objetivos requiere de una participación e involucración completa por parte de todos los ciudadanos.